



TAMPEREEN
AMMATTIKORKEAKOULU

ENNUSTAVAN VIKADIAGNOSTIIKAN KEHITYS JA ETÄKUNNONVALVONNAN HYÖDYNTÄMINEN NRMM- LIIKETOIMINTASEGMENTISSÄ

Kimmo Riuttala

Opinnäytetyö
Marraskuu 2016

Ylempi ammattikorkeakoulututkinto
Teknologiaosaaminen johtaminen



TIIVISTELMÄ

Tampereen ammattikorkeakoulu
Ylempi ammattikorkeakoulututkinto
Teknologiaosaamisen johtaminen

RIUTTALA, KIMMO:

Ennustavan vikadiagnostiikan kehitys ja etäkunnonvalvonnan hyödyntäminen NRMM-liiketoimintasegmentissä

Opinnäytetyö 56 sivua, joista liitteitä 2 sivua
Marraskuu 2016

Tämän työn tarkoituksena oli tutkia dieselmootoreita valmistavalle AGCO Power Oy:lle koneoppimiseen perustuvaa ennakoivan vikadiagnostiikan toteutusta. Lisäksi työn piti antaa yrityksen johdolle todisteita etäkunnonvalvonnan hyödyistä, jotta kehitystyötä aiheen parissa jatkettaisiin. Tarkoituksena on tulevaisuudessa yhdistää ennustava vikadiagnostiikka ja etäkunnonvalvonta toisiinsa, minkä vuoksi molempia tutkittiin samanaikaisesti.

AGCO Power Oy valmistaa vuosittain globaalisti yhteensä noin 50,000 dieselmootoria samaan konserniin kuuluville työkonevalmistajille ja kolmansille osapuolille, jotka toimivat NRMM (Non-Road Mobile Machinery) -liiketoimintasegmentissä. Kentällä olevan suuren moottorivolyymien vuoksi vikadiagnostiikan tulisi täten olla automatisoitua ja työkoneiden etänä seurattavia.

Työssä keskityttiin koneoppimisen teknologian tarkasteluun sekä vikadiagnostiikan kehitykseen algoritmien avulla. Lisäksi mietittiin uuden teknologian mahdollistamia hyötyjä sisäisille ja ulkoisille sidosryhmille.

Tutkimus toteutettiin case-tyyppisenä, jossa tutkittiin yhtä moottorin ongelmatapausta ja siihen liittyvää ennustettavan vikadiagnostiikan toteutusta. Ennustettavuutta testattiin Microsoft Azure Machine Learning koneoppimispalvelussa. Työ sisälsi paljon erilaista määrittely- ja selvitystyötä sekä luovaa ajattelutapaa liiketoiminnan hyötyjä pohdittaessa.

Koneoppimispalvelusta saadut tulokset osoittivat, että älykkäillä algoritmeilla voidaan ennakoida muutoksia datassa. Kehitystyötä tulee kuitenkin edelleen jatkaa, jotta ennustettavuus saadaan optimoitua ja toiminta implementoitua etäkunnonvalvontaan. Uusia teolliseen internetiin perustuvia palvelumuotoja ideoitiin, joita voidaan käyttää liiketoimintamallin kehityksessä.

Työn tuloksena AGCO Powerilla on lisääntynyt tietoisuus etäkunnonvalvonnan hyödyistä. Konkreettisena asiana hankitaan etämonitorointiin tarkoitettuja datatallentimia, joita tullaan käyttämään Stage V päästövaiheen moottoreita validoitaessa. Tietoa kerätään moottoreiden käyttäytymisestä ja sitä voidaan hyödyntää myöhemmässä vaiheessa ennakoivan vikadiagnostiikan kehitykseen. Työ on herättänyt mielenkiintoa myös muissa funktioissa, kuten laadussa ja tuotannossa, joissa aiotaan tutkia koneoppimisen soveltamista päivittäiseen toimintaan.

Asiasanat: etäkunnonvalvonta, ennustava vikadiagnostiikka, teollinen internet, koneoppiminen

ABSTRACT

Tampere University of Applied Sciences
Master's Degree Programme in Strategic Leadership of Technology-based Business

RIUTTALA, KIMMO:

Developing predictive fault diagnostics and studying remote condition monitoring benefits in NRMM business segment

Master's thesis 56 pages, appendices 2 pages
November 2016

Purpose of the thesis was to study feasibility of predictive fault diagnostics for AGCO Power Inc. by using machine learning technology. Thesis was also supposed to give evidence to company's top management about benefits of remote condition monitoring, so that development work would continue later on. Purpose in the future is to combine both predictive fault diagnostics and remote condition monitoring thus they were studied together.

AGCO Power Inc. produces totally about 50,000 diesel engines annually for AGCO Corporation and third party customers who operate in the NRMM (Non-Road Mobile Machinery) business segment. Since engine volumes are so high, it would be favorable to have an automatic fault diagnostics system.

Work focused on reviewing machine learning technology and developing smart algorithms for fault monitoring. Furthermore benefits of new technology were studied for internal and external stakeholders.

Research work was carried out as a case type where feasibility of fault predictability was examined for one engine problem example. Predictability was tested by using Microsoft Azure Machine Learning tool. Work included lots of different kind of defining work and creative thinking when considering new business model ideas.

Machine learning tool results showed that changes in data can be anticipated by using smart algorithms. Despite of promising results, further research work is required to optimize algorithms' operation before they can be implemented in remote condition monitoring. New ideas for service business were studied and they can be used when developing business models.

Knowledge of remote condition monitoring benefits has been increased at AGCO Power as a result of this study. Concrete action will be to acquire data loggers that will remotely collect information of Stage V prototype engines. Data will be used for validating new components and developing predictive fault diagnosis. Machine learning has aroused interest also in other functions such as quality and production. Its usage for daily work will be studied.

Key words: remote condition monitoring, predictive fault diagnostics, industrial Internet, machine learning

SISÄLLYS

1	JOHDANTO.....	7
1.1	Taustatietoa	7
1.1.1	AGCO konserni ja AGCO Power Oy	7
1.1.2	Markkinatietoa	8
1.1.3	Liikevaihto	9
1.2	Opinnäytetyön tavoite.....	10
1.3	Tutkimusmenetelmä.....	10
1.4	Rajaukset.....	11
1.5	Työn rakenne	11
2	TYÖN LÄHTÖKOHDAT	12
2.1	Etäkunnonvalvonnan nykytila AGCO:lla.....	12
2.1.1	AGCO Fuse-yhteyspalvelu	12
2.1.2	AgCommand etäkunnonvalvontaohjelma.....	14
2.2	Moottorin vikadiagnostiikka.....	15
2.2.1	Moottorin väylätekniikka – CAN ja SAE J1939.....	16
2.2.2	Vikadiagnostiikkaohjelmat – WinEEM4 ja EDT	17
2.2.3	Nykyinen öljynpaineen vikadiagnostiikan toimintatapa.....	18
2.3	AGCO Power jälkimarkkinoinnin ja tuotekehityksen nykyiset haasteet.....	19
3	UUDEN TEKNOLOGIAN PERUSTEET	21
3.1	Teollinen internet, IoT	21
3.2	Koneoppiminen.....	23
3.2.1	Algoritmit.....	24
3.2.2	Ohjattu oppiminen.....	25
3.2.3	Bayes-verkot	26
3.2.4	Päätöspuut	27
3.2.5	Esimerkkejä koneoppimisen käytännön sovelluksista.....	28
4	KONEOPPIMISEN HYÖDYNTÄMINEN VIKADIAGNOSTIIKASSA.....	30
4.1	Esitys uudesta vikadiagnostiikan toimintamallista	30
4.2	Ennustavan vikadiagnostiikan kehitys öljynpaineen seurantaan	31
4.2.1	Koneoppimispalvelun valinta	32
4.2.2	Algoritmimallin valinta.....	33
4.2.3	Demovaihe	34
4.2.4	Tulosten analysointi ja yhteenveto Microsoft Azure ML käytöstä.....	39

5	PALVELULIIKETOIMINNAN KEHITYS JA	
	ETÄKUNNONVALVONNAN HYÖDYT SIDOSRYHMILLE	41
5.1	Teollisen internetin mahdollistamat uudet palvelut.....	41
5.2	Etäkunnonvalvonnan vertailuanalyysi	42
5.2.1	Wärtsilä Oyj - CBM	42
5.2.2	Komatsu Forest Oy - MaxiFleet.....	44
5.3	Hyödyt sisäisille sidosryhmille	45
5.3.1	Tuotekehitys	46
5.3.2	Jälkimarkkinointi	47
5.4	Hyödyt ulkoisille sidosryhmille.....	48
6	POHDINTA.....	50
	LÄHTEET	52
	LIITTEET	55

ERITYISSANASTO

AP	AGCO Power Oy
NRMM	Non-Road Mobile Machinery, liikkuvat työkoneet
IoT	Internet of Things
ML	Machine Learning
CAN	Controller Area Network
SAEJ1939	CAN-väylään pohjautuva sovelluskerroksen protokolla
ECU	Electronic Control Unit, moottorin ohjausyksikkö
WinEEM4	AGCO Powerin diagnostiikkaohjelma
EDT	Electronic Diagnostic Tool
Big Data	Valtavien ja jatkuvasti kasvavien tietomassojen kerääminen, säilyttäminen, jakaminen ja analysointi

1 JOHDANTO

1.1 Taustatietoa

Älykkäät järjestelmät sekä laitteiden yhdistäminen toisiinsa ja verkkoon ovat tuoneet uusia mahdollisuuksia yritysten palveluihin ja liiketoimintamalleihin. Saksalaisten kehittämä termi Teollisuus 4.0 kuvaa tämän hetkistä aikakautta teollisuudessa, jossa hyödynnetään virtuaalimaailmoja, integraatioita laitteiden ja järjestelmien välillä sekä älykkäitä ohjelmistoja (Tekniikka & Talous 2014). Tämä tunnetaan paremmin termeillä ”Iot - esineiden internet” tai ” Ubiquitous computing – läsnä-äly”. Usein siihen yhdistetään myös pilvipalvelut, joissa tiedon prosessointi suoritetaan tehokkailla tietokoneilla. Dieselmootoreita valmistavalle AGCO Power Oy:lle Teollisuus 4.0 mahdollistaa moottorin etäkunnonvalvonnan uuden teknologian avulla sekä pilvipalvelusta saatujen tietojen analysoinnin ja ennakoivan vikadiagnostiikan. Tässä työssä tutkitaan näiden käyttömahdollisuuksia ja hyötyjä sidosryhmille.

1.1.1 AGCO konserni ja AGCO Power Oy

AGCO konserni on perustettu vuonna 1990 ja se on yksi maailman johtavista traktoreiden ja maatalouskoneiden valmistajista. Pääkonttori sijaitsee Duluthissa, Yhdysvalloissa ja toimitusjohtajana toimii saksalainen Martin Richenhagen. AGCO konsernilla on yhteensä 25 tehdasta 13 eri maassa ja tuotteiden jakelusta vastaa maailmanlaajuisesti noin 3000 jälleenmyyjää 140 eri maassa. AGCO:n päämääränä on tuottaa huippuluokan ratkaisuja maailmaa ruokkiville maanviljelijöille ja saavuttaa kannattavaa kasvua ainutlaatuisella asiakaspalvelulla, innovaatioilla ja laadulla. (AGCO Corporation 2016.)

Konsernin viisi maailmanlaajuisesti tunnettua brändiä ovat Challenger, GSI, Fendt, Massey Ferguson ja Valtra. Kaikki muut brändit toimivat NRMM (Non-Road Mobile Machinery) -liiketoimintasegmentillä eli tekevät liikkuvia työkoneita, paitsi GSI, joka valmistaa muun muassa viljasiiloja sekä eläinten ruokintalaitteistoja. AGCO konserni on näin ollen laajentanut toimintansa kokonaisvaltaiseksi maataloustoimittajaksi. (AGCO Corporation 2016.)

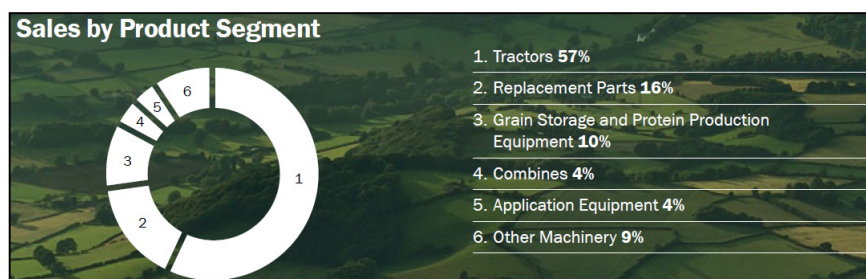
Vuonna 2004 AGCO konserni osti Valtran traktoriliiketoiminnan Suomessa ja Brasilissa sekä silloisen Sisu Dieselin moottoritehtaat Nokian Linnavuorella ja Brasilian Mogi das Gruzesissa. Vuonna 2008 Sisu Diesel nimi muutettiin AGCO Sisu Power Oy:ksi ja nykyään yritys tunnetaan nimellä AGCO Power Oy. Kolmas moottoritehdas perustettiin vuonna 2012 Kiinan itärannikolle Changzhou nimiseen kaupunkiin. (AGCO Power 2016a.)

Moottoreita valmistetaan Linnavuorella vuosittain noin 30,000 kappaletta ja loput 20,000 moottoria jakaantuvat Kiinan ja Brasilian tehtaiden kesken. Valtaosa moottoreista on viimeisimmän päästövaatimuksen (Stage 4) täyttäviä työkonedieselmoottoreita kokoluokissa 3,3–16,8 litraa, teholuokissa 44–500 kW. Moottoreiden lisäksi yritys valmistaa Suomessa vaihteistoja, akseleita, hammaspyöriä sekä dieselgeneraattoreita. (AGCO Power 2016b.)

AGCO konserni käyttää vuosittain tuotteissaan yli 75,000 dieselmoottoria, joten AGCO Powerilla on hyvät mahdollisuudet kasvaa voimakkaasti yhtiön sisällä (AGCO Power 2016a). Konsernin vahva panostus Linnavuoren dieselmoottorituotantoon on tuonut lisää töitä suomalaisille ja lisäksi muutama vuosi sitten rakennettiin uusi moderni tuotantohalli isommille moottoreille.

1.1.2 Markkinatietoa

AGCO on saavuttanut vahvan markkinaosuuden maataloudessa keskittymällä johtavaan teknologiaan, kattavaan jälleenmyyntiverkostoon sekä asiakastukeen. AGCO konsernin myynnistä tulee 57 % traktoreista, 16 % varaosista, 10 % viljanvarastointivarusteista, 4% puimureista, 4% lisäosista ja 9% muista tuotteista, kuten kuvassa 1 on esitetty. (AGCO Corporation 2015.)



KUVA 1. AGCO konsernin myynti tuotealueittain (AGCO Corporation 2015)


1.1.3 Liikevaihto

AGCO konsernin liikevaihto vuonna 2015 oli yhteensä lähes 7,5 miljardia dollaria. Siitä 53% tulee myynnistä EAME-alueelta, 25% Pohjois-Amerikasta, 17% Etelä-Amerikasta ja loput 5% Aasiasta. (AGCO Corporation 2015.)

Taulukkoon 1 on kerätty sekä AGCO konsernin että huolto- ja varaosabisneksen liikevaihto miljoonissa dollareissa vuosina 2011–2015. Kuviossa 1 näkyy tarkemmin huolto- ja varaosabisneksen osuus koko konsernin liikevaihdosta prosentteina. Trendi on ollut jokseenkin nousujohteinen viime vuosina, joka johtuu osaksi uusien työkoneiden myynnin vähenemisestä. Asiakkaat ovat täten panostaneet olemassa olevien työkoneiden huoltoihin uusien ostamisen sijasta. Lyhyellä aikavälillä tähän ei ole tulossa merkittävää muutosta, joten etenkin IoT-palveluiden kehittäminen on tällä hetkellä AGCO konsernin yhtenä tärkeimpänä tavoitteena. (AGCO Corporation 2015.)

TAULUKKO 1. AGCO konsernin avainluvut miljoonissa dollareissa vuosina 2011–2015 (AGCO Corporation 2015)

	2015	2014	2013	2012	2011
AGCO konsernin liikevaihto \$	7467,3	9723,7	10786,9	9962,2	8773,2
AGCO Parts (varaosa- ja huoltobisnes) \$	1185,9	1175,6	1128,7	1081,4	986,1



KUVIO 1. AGCO Parts osuus liikevaihdosta vuosina 2011–2015

1.2 Opinnäytetyön tavoite

Opinnäytetyön tarkoituksena on vastata kysymykseen ”*Millä tavoin eri sidosryhmät hyötyisivät etäkunnonvalvonnasta ja miten vikadiagnostiikkaa voisi kehittää uuden teknologian avulla?* Tarkemmin sanottuna työ keskittyy koneoppimiseen perustuvaan ennakoivan vikadiagnostiikan tutkimiseen, etäkunnonvalvonnan hyötyjen pohdintaan sisäisille ja ulkoisille sidosryhmille sekä palveluliiketoiminnan ideointiin NRMM-liiketoimintasegmentissä. Sisäisellä sidosryhmällä tarkoitetaan esimerkiksi AGCO Powerin tuotekehitystä ja ulkoisella työkoneen loppukäyttäjiä. Ennakoivan vikadiagnostiikan hyötyesimerkkinä voidaan muun muassa mainita mahdollisuus vaikuttaa huoltojen ennustettavuuteen. Tämä taas johtaa parempaan asiakaspalveluun ja työkoneen toimintavarmuuteen, kun määräaikaishuoltojen yhteydessä voidaan hoitaa orastavat viat etukäteen ilman huoltokatkoja. Työn lopussa on tälle laajempi pohdintaosuus.

1.3 Tutkimusmenetelmä

Työ toteutetaan case-tutkimuksena, eli tarkoituksena on kerätä aineistoa tietyistä tapauksista ja analysoida sitä. Case-tutkimus on kvalitatiivisen ja kvantitatiivisen tutkimuksen yhdistelmä. Tällaista lähestymistapaa tarvitaan silloin, kun pelkkä määrällinen tai laadullinen tutkimusote ei pelkästään riitä. (Kananen 2013, 23.) Case-tutkimuksen avulla pystytään ymmärtämään yrityksen toimintatapoja paremmin. Tyypillistä tällaisessa tutkimuksessa on, että tutkimuksen kohteena on yleensä yritys tai sen tietty prosessi, toiminto, tapahtumasarja. (Koskinen, Alasuutari & Peltonen 2005, 154–157.) Luotettavuuden kannalta tärkeintä on se, että esitetty tieto pystytään perustelemaan, todistamaan ja osoittamaan paikkansapitäväksi. Samalla on hyvin tärkeää tuoda tutkijan oma näkemys esille tutkimustuloksissa. (Kananen 2013, 122.) Tässä opinnäytetyössä pyritään kuvaamaan miten dieselmoottorin vikadiagnostiikkaa suoritetaan ja miten koneoppimisen avulla sitä voisi kehittää laajempaa käyttöä varten.

1.4 Rajaukset

Opinnäytetyössä tutkitaan yhtä vikadiagnostiikan käyttötapausta, joka valitaan tärkeyden perusteella. Analysoitavaksi otetaan täten moottorissa hyvin keskeisessä roolissa oleva öljynpaine, jonka tulee olla riittävällä tasolla, jotta sisäisiä komponentteja kuten kampiakselin laakereita pystytään voitelemaan käytön aikana. Mikäli öljynpaine on liian alhainen, saattaa se tehdä moottorista täysin käyttökelvottoman ja aiheuttaa omistajalle suuren rahallisen vahingon sekä moottorin valmistajalle imagon menetyksen. Se on siis hyvin oivallinen tutkimuskohde siinä mielessä.

Työssä pyritään selvittämään öljynpaineen vikaantumisen ennustettavuus Microsoft Azure ML palvelun avulla, jossa algoritmeja voidaan kouluttaa ja testata. Työssä käsitellään useimmiten koneoppimisessa käytettyjä algoritmeja vain yleisellä tasolla, eikä itse ohjelmointiin oteta kantaa.

Etäkunnonvalvontaan liittyen mietitään uusia palvelumahdollisuuksia AGCO konsernille sekä hyötyjä AGCO Power Linnavuoren tuotekehitykselle ja jälkimarkkinoinnille. Ulkoisista sidosryhmistä käsitellään yksityisasiakkaat, yritykset ja viranomaiset.

1.5 Työn rakenne

Luvussa 1 esiteltiin lyhyesti yritys, tutkimusmenetelmä, tavoitteet ja rajaukset. Luvussa 2 tarkastellaan tutkimuksen lähtökohtia tuotekehityksen ja jälkimarkkinoinnin näkökulmasta. Luvussa 3 käsitellään uuden teknologian perusteita koneoppimisen ja algoritmien kautta. Luvussa 4 pohditaan vikadiagnostiikan kehitystä sekä testataan algoritmien toimintaa käytännössä Microsoft Azure ML ohjelmassa. Luvussa 5 mietitään IoT-teknologian vaikutuksia liiketoimintaan, vertaillaan etäkunnonvalvontaa yrityksissä ja kuvaillaan hyötyjä sidosryhmille. Luvussa 6 on esitetty loppupäätelmät, jatkotoimenpiteet ja ehdotukset palveluliiketoiminnan kehittämiseen tulevaisuudessa.

2 TYÖN LÄHTÖKOHDAT

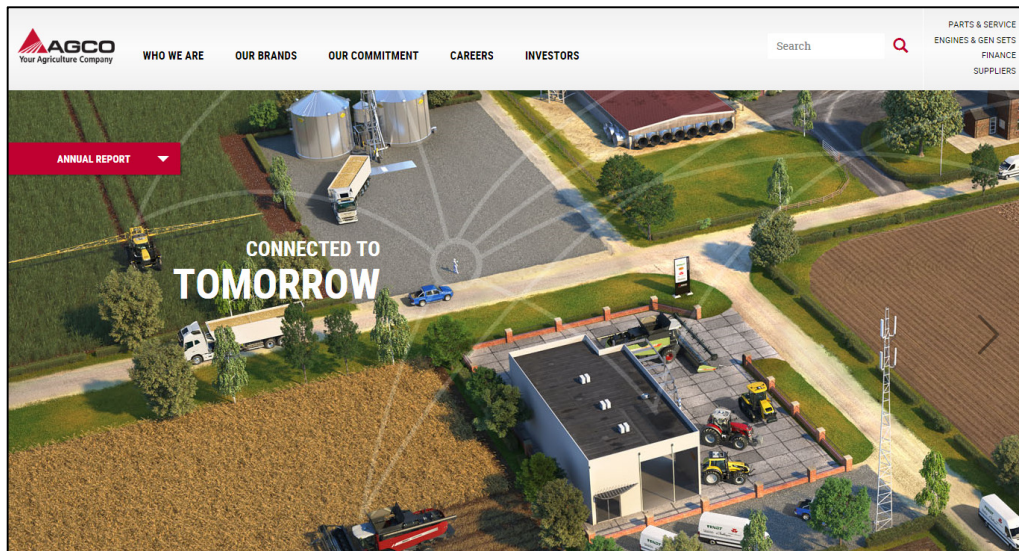
2.1 Etäkunnonvalvonnan nykytila AGCO:lla

AGCO:n työkoneet ovat nykyään mahdollista yhdistää toisiinsa ja verkkoon Gateway nimisen päätelaitteen avulla. Datat välityksessä pilvipalveluun käytetään sekä mobiili-verkkoja että satelliitteja, joten seurannalla on mahdollista kattaa hyvin suuri osa loppukäyttäjistä. Tällä hetkellä käyttö on vielä hyvin rajallista ja yhteyslaitteiden hankinta vaatii asiakkailta useiden tuhansien dollareiden rahallista panostusta. Pienen volyymin vuoksi laitteet ovat vielä kalliita. Yhtenä syynä etäkunnonvalvonnan vähäiseen käyttöön on myös se, että asiakkaat eivät koe saavansa palvelusta lisäarvoa, koska työkoneet ovat yleisesti luotettavia ensimmäisten vuosien ajan.

Yhteyspalvelua markkinoidaan AGCO Fuse nimellä ja se tuo esineiden internetiin perustuvia ratkaisuja asiakkaiden ulottuville. Tähän kuuluu osana myös AgCommand niminen pääteohjelma, jonka kautta työkoneen dataa on nähtävillä lokaalisti käyttäjälle ja AGCO:n huolto-organisaatiolle. Tällä hetkellä se ei kuitenkaan palvele AGCO Poweria, jotta moottoreiden tarkempi vikadiagnostiikka olisi mahdollista. Moottorista voidaan muun muassa nähdä vain vikakoodit, kuormatiedot, polttoaineen kulutus ja käyttötunnit. Suurin osa datasta jää tällä hetkellä hyödyntämättä ja sitä on niin valtava määrä, etteivät ihmiset pysty analysoimaan tietoja reaaliajassa. Tämän vuoksi olisi kehitettävä koneoppimiseen perustuva automaattinen vikadiagnostiikka.

2.1.1 AGCO Fuse-yhteyspalvelu

AGCO:lla on saatavilla Pohjois-Amerikassa ja Euroopassa loppukäyttäjille Fuse-yhteyspalvelu, joka hyödyntää integraatioita verkkoon kytkettyjen laitteiden ja järjestelmien välillä. Sen avulla voidaan tarjota erilaisia palveluita kuten huoltoneuvontaa, varaosia, optimointia ja työkoneiden käytön maksimointia. Yleisesti sitä käytetään niin sanottuun ”fleet managementtiin” eli suomeksi käännettynä laivueen hallintaan. Pääteohjelmalla tilan omistajat voivat tarkkailla muun muassa työkoneiden sijainteja ja kuljettuja reittejä. (AGCO Fuse 2015a.)



KUVA 2. Fuse-yhteyspalvelun esite AGCO konsernin internet sivulla (AGCO Fuse 2015b)

Fuse-yhteyspalvelussa yhdistyvät AGCO konsernin varaosapalvelut (AGCO Parts), huolto (AGCO Service) ja tekniset huippuluokan ratkaisut (AGCO ATS). Palvelu on suunniteltu parantamaan asiakkaiden tilojen tehokkuutta vähentämällä työkonoiden huolto- ja ylläpitokustannuksia. Lisäksi sen avulla omistajat saavat tietoa tärkeiden bisnespäätösten tueksi. Kuvassa 2 on esitetty työkonoiden ja asiakkaan järjestelmien liitettävyyttä toisiinsa ja verkkoon. (AGCO Fuse 2015a.)

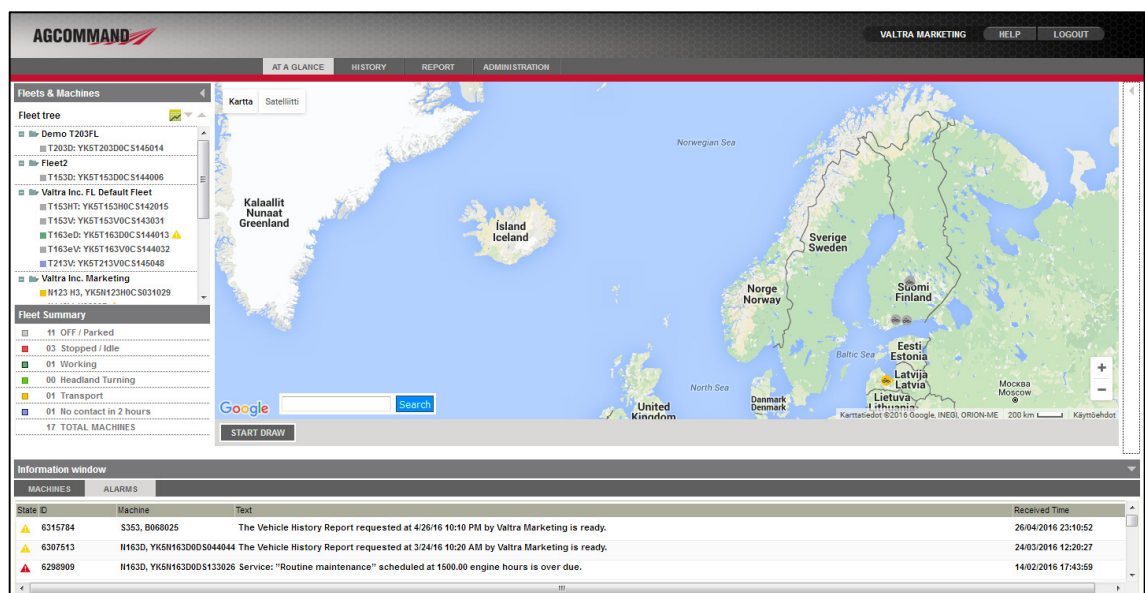
Yhteyspalvelussa on tarjolla eri tason paketteja, joissa tukipalvelun ominaisuudet vaihtelevat. Alemman tason avulla asiakkaat voivat itse suorittaa monitorointia, tiedonsiirtoa, kalibrointia ja saavat tukea tarvittaessa puhelimitse, internet chatin tai sähköpostin kautta. Ylemmän tason paketissa on tarjolla jälleenmyyjien suorittamaa aktiivista seurantaa, puintikauden ulkopuolella olevia tarkastuskäyntejä, konsultaatiota ja käyttökoulutusta. Huoltopaketit voidaan räätälöidä asiakkaan halujen mukaan, joten hinnat ja ominaisuudet vaihtelevat suuresti. (AGCO Fuse 2015a.)

AGCO Fuse on saatavilla vuonna 2016 Challenger ja Gleaner brändeille Pohjois-Amerikassa ja Fendtille Euroopassa. Muita brändejä ja alueita tullaan testaamaan vuonna 2017. (AGCO Fuse 2015a.)

2.1.2 AgCommand etäkunnonvalvontaohjelma

AGCO Fuse-yhteyspalveluun kuuluva AgCommand etäkunnonvalvontaohjelma tarjoaa loppukäyttäjille monia erilaisia palveluita. Käyttöliittymästä asiakkaan on mahdollista nähdä tietoa omasta työkoneesta ja tehdä sen avulla päätöksiä, joilla voi vähentää käyttökustannuksia ja minimoida seisonta-aika.

AgCommand pitää tarkkaa kirjaa traktorin liikkeistä ja sijainnista. Seurantajärjestelmä perustuu GPS-satelliittipaikannukseen, ja sen avulla voidaan seurata esimerkiksi työkonen sijaintia (kuva 3), toteutettavaa työtehtävää, työn tehokkuutta ja huollon tarvetta internetiin yhdistetyltä tietokoneelta tai mobiililaitteelta. Tiedot välitetään traktorista järjestelmään GSM-verkon kautta, eikä se edellytä kuljettajalta mitään toimia. (Valtra Teknologiaratkaisut 2016.)




KUVA 3. AgCommand etäkunnonvalvontaohjelman paikannusnäkymä

AgCommand tallentaa traktorin liikkeitä ja sen tekemän työn internetin kautta pilvipalvelimelle, josta työkonen sijainti ja työtehtävän tehokkuus voidaan jäljittämään milloin tahansa ja miltä tahansa valitulta ajanjaksolta. Työtehtävien seuraamisesta ja raportoinnista on etua erityisesti useampaa työkonetta käyttäville urakoitsijoille. Myös vuokrattujen työkonien seuranta käy helposti ja laajasti. Järjestelmän tarkkuus riittää pienimpienkin peltolohkojen työvaiheiden jäljittämiseen. (Valtra Teknologiaratkaisut 2016.)

2.2 Moottorin vikadiagnostiikka

Moottorin vikadiagnostiikka perustuu analogisten ja digitaalisten signaalien analysointiin ohjausyksikössä eli ECU:ssa, jota AGCO Powerin kehittämä Sisutronic-ohjelmisto suorittaa jatkuvasti työkonteen virtojen ollessa päällä. Diagnostiikalle on luotu tietyt säännöt ja vikakoodit aktivoituvat tietyissä määritellyissä rajoissa sekä tilanteissa. Vikojen analysointi on jossain tapauksissa erittäin monimutkaista ja tietoa tutkitaan monista eri parametreista yhtä aikaa.

Tietoa liikkuu edestakaisin moottorin ja työkonteen välillä CAN-väylää pitkin. Muun muassa vikakoodit siirtyvät moottorin ohjausyksiköstä CAN-väylää pitkin työkonteen ohjauspaneelille näytettäväksi. Kuvassa 4 on esitelty traktorissa olevaa tiedonsiirtojärjestelmää hyvin yksinkertaistetusti muutamalla väylään liitettyllä komponentilla. Siitä nähdään, että moottorin ECU:n ja antureiden/toimilaitteiden välinen tiedonsiirto on perus I/O:ta, mutta muuten työkonteen tiedot kulkevat CAN-väylässä.



KUVA 4. Tiedonsiirto moottorin ja traktorin komponenttien välillä

2.2.1 Väylätekniikka – CAN ja SAE J1939

CAN-väylä on Robert Bosch GmbH:n 1980-luvun alussa kehittänyt sarjajärjestelmä ajoneuvoteollisuuden käyttöön. Myöhemmin siitä on tullut suosittu myös teollisuusautomaatiossa. Yleensä CAN-väylää käytetään sulautetuissa järjestelmissä, joissa tarvitaan nopeaa tiedonsiirtoa mikrokontrollereiden välillä. (Wilfried 2005, 2-3.)

CAN-väylässä liikkuu muun muassa työkonen tietoja, joita moottorin elektroninen ohjainyksikkö hyödyntää. CAN-väylästä pystytään lukemaan esimerkiksi pyödetty kierrosnopeus ja anturitietoja, jotka vaikuttavat moottorin toimintaan. Laitteet, jotka tarvitsevat jonkin tiedon, voivat lukea niitä yhtä aikaa. Tarvittaessa väylään voidaan myös helposti lisätä laitteita. Tämä ominaisuus on tarpeellinen esimerkiksi prototyyppimoottorien testauksessa.

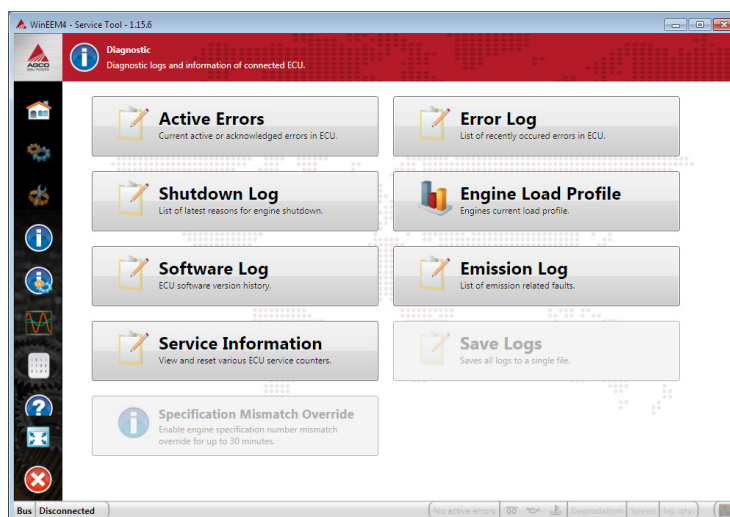
Yhdysvaltalainen SAE (Society Of Automotive Engineers) on autoalan standardisointijärjestö, joka on kehittänyt raskaan kaluston standardin J1939. J1939 on sovelluskerroksen protokolla, joka hyödyntää CAN-standardin fyysistä kerrosta. J1939 standardi käyttää laajennettua CAN-standardia, jossa on 29 bittinen viestin tunnistekenttä. (Wilfried 2008, 5.)

AGCO Powerin moottoreissa vikakoodit on luotu käyttäen J1939 standardia, joka on yleisesti käytössä ajoneuvoteollisuudessa. Vikakoodi sisältää FMI (Failure Mode Identifier) ja SPN (Suspect Parameter Number) koodit tunnistusta varten. Jokaiselle vikakoodille on luotu oma yksilöllinen tunniste. Esimerkiksi vikakoodi SPN100-FMI1 tarkoittaa, että öljynpaine on kriittisen alhainen.


2.2.2 Vikadiagnostiikkaohjelmat – WinEEM4 ja EDT

Vikojen diagnosoimiseen on käytössä WinEEM4 (kuva 5) ja EDT (Electronic Diagnostic Tool) työkalut. WinEEM4 on AP:n tuotekehityksen käytössä ja EDT:tä käytetään AGCO konsernin huoltopisteissä ympäri maailman. Molemmissa on paljon samoja vikadiagnostiikan toiminnallisuuksia. Moottoriin joutuu kuitenkin olemaan fyysisesti yhteydessä, jotta vikakoodit ja tarkat parametrien arvot saadaan selville. Yksi mahdollisuus on myös nauhoittaa dataa ja lähettää se sähköpostitse analysoitavaksi.

WinEEM4:llä voidaan tarvittaessa nähdä kaikki moottorin CAN-väylän liikenne, josta kokenut ekspertti voi tehdä päätelmiä vioista. Esimerkiksi oskilloskooppisivulle saa kerättyä erilaisia parametreja vertailtavaksi oskilloskooppinäyttöön (kuva 6), mutta sen käyttö ei ole erityisen käyttäjäystävällistä ja vaatii paljon kokemusta.



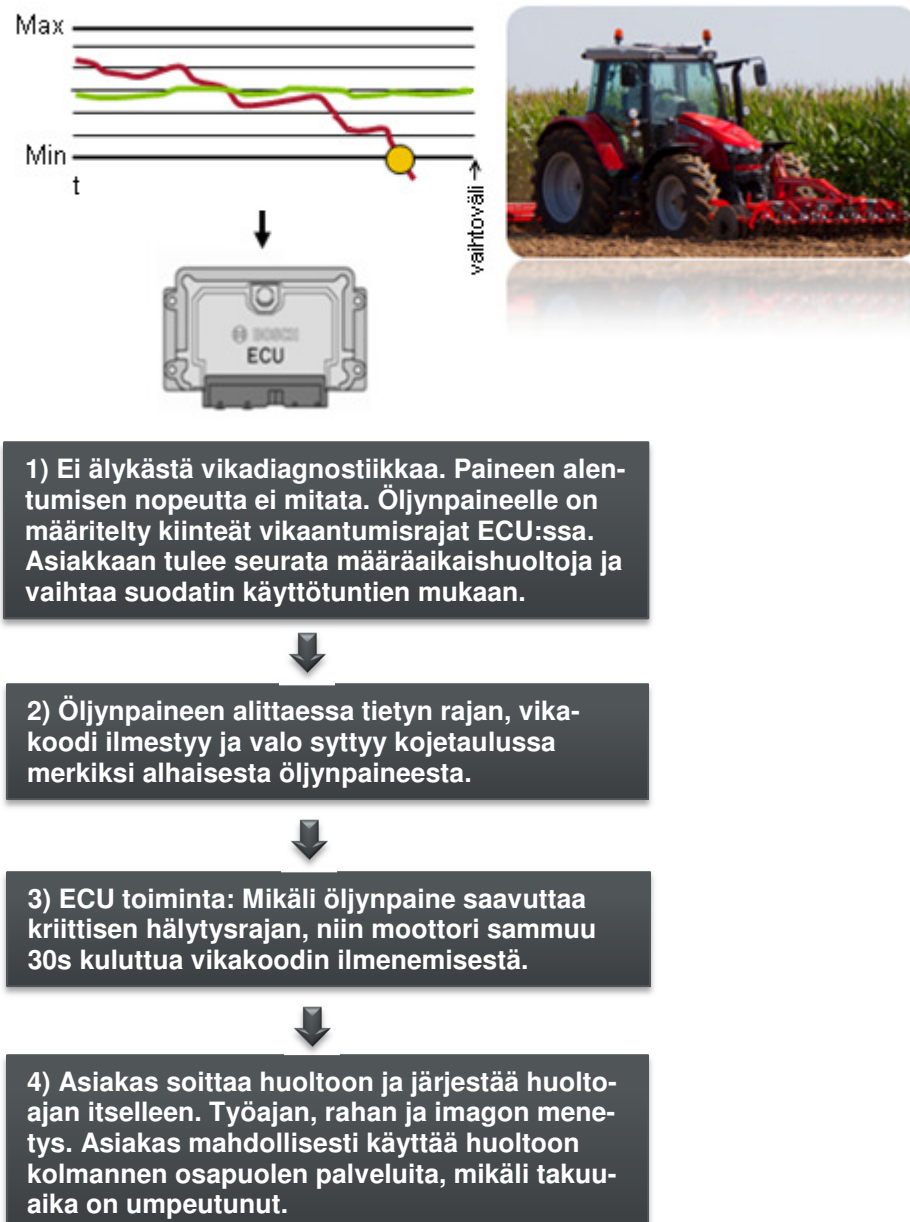
KUVA 5. WinEEM4 ohjelman vikadiagnostiikkasivu



KUVA 6. WinEEM4 ohjelman oskilloskooppinäkymä eri parametreille

2.2.3 Nykyinen öljynpaineen vikadiagnostiikan toimintatapa

Alla on esitetty esimerkkinä miten öljynpaineen vikadiagnostiikka suoritetaan tällä hetkellä moottorin ohjausyksikössä eli ECU:ssa. Kuvan 7 asteikolla on esitetty öljynpaineen mittausdata punaisena linjana ja sen käyttäytyminen ajan (t) funktiona. Kuvaajasta nähdään, että paine vähenee huomattavalla nopeudella verrattuna normaaliin käyttäytymiseen (vihreä linja) ja ennen kuin normaali suodattimen vaihtoväli saavutetaan. Vikakoodi alhaisesta öljypaineesta ilmestyy työkoneseen kojetauluun varoitukseksi hieman ennen kriittisen hälytysrajan saavuttamista (keltainen pallo). Tämän jälkeen menee 30 sekuntia kunnes ECU sammuttaa moottorin.



KUVA 7. Nykyinen öljynpaineen vikadiagnostiikan kuvaus

Syynä öljynpaineen epänormaaliin käyttäytymiseen voi olla esimerkiksi:

- Moottorin öljymäärä on liian alhainen
- Öljyn laatu on heikkoa
- Öljynsuodatin on tukossa
- Öljyn tyyppi on väärä
- Öljy on liian kuumaa
- Öljynpaineen säätöventtiili ei toimi oikein
- Öljypumppu on liian kulunut
- Öljynpaineanturin johdotus on viallinen
- Öljynpaineanturi on viallinen

2.3 AGCO Power jälkimarkkinoinnin ja tuotekehityksen nykyiset haasteet

Omiin kokemuksiin perustuen olen kerännyt tähän muutamia esimerkkejä ongelmista, joita AP:n jälkimarkkinoinnissa ja tuotekehityksessä on tällä hetkellä liittyen moottoridatan analysointiin tai sen puutteeseen.

Tuotekehityksen osalta uusien moottorien validoinnit eli testaukset ennen sarjatuotantoa ovat hajautettu ympäri maailmaa. Tämä täytyy luonnollisesti tehdä, jotta saadaan tarpeeksi kattava otanta moottoriin vaikuttavista erilaisista olosuhteista. Moottoridatan saanti ulkomailta on kuitenkin osoittautunut hyvin vaikeaksi ja useimmiten tietoa saadaan vain käyttötunneista sekä ilmenneistä vioista excel-taulukon muodossa. Myös vavainen englannin kielen taito ja kokemattomat koeajajat ovat osa ongelmaa, eikä vioista saada tarpeeksi tarkkoja kuvauksia. Vialliset komponentit kyllä saadaan tarvittaessa Linnavuoreen AP:lle, mutta tarkempi analysointi ilman moottoridataa on hyvin vaikeaa, jollei mahdotonta. Mikäli haluaa saada live-dataa, on mentävä itse paikanpäälle nauhoittamaan tietoa huoltotyökalun kanssa.

Sarjatuotannon alettua työkoneita menee entistä laajempaan käyttöön ja tällä hetkellä ensimmäisten kymmenien tuntien osalta ei nähdä millaisia ongelmia asiakkaat kentällä kokevat, muuta kuin jos työkone viedään huollettavaksi AGCO:n huoltopisteeseen. Siinäkin menee vielä kauan aikaa kunnes tietoa saadaan AP:lle asti, vaikka AGCO konsernilla on käytössään internet-pohjainen takuujärjestelmä. Olisikin ensisijaisen tärkeää

nähdä tällaista tietoa moottorin ensitunneista, jotta ongelmiin voidaan puuttua mahdollisimman nopeasti ja tehdä niin sanottu nopeutettu tuotekehitys.

Jälkimarkkinoinnin haasteet liittyvät pitkälti datan puutteeseen takuuanomuksia käsitellessä. Anomuksia tulee ympäri maailman ja epäselvät vikakuvaukset käännösvirheiden eivät juuri anna mahdollisuutta löytää juurisyytä ongelmalle. Näin ollen anomukset yleensä hyväksytään, koska ei ole tarkempaa tietoa saatavilla. Moottorista on harvoin mahdollista saada esimerkiksi kuormaprofiilia, josta näkisi millaista ajoa sillä on tehty ja minkälaisissa olosuhteissa. Lisäksi moottorin ohjausyksikön muistiin on tällä hetkellä mahdollista tallentaa vain toistakymmentä vikakoodia, jonka jälkeen uudet kirjoitetaan edellisten päälle. Moottoridatan puute vaikuttaa täten suoraan AP:n maksamiin takuukorvauksiin ja sen kehitys toisi varmasti säästöjä puhumattakaan tärkeästä informaatiosta asiakastytyväisyyden vahvistamisessa toimintavarmuuden avulla.

3 UUDEN TEKNOLOGIAN PERUSTEET

3.1 Teollinen internet

Teollinen internet on osa uutta digitalisaation muutosta, jossa internet verkkoon kytketyt tuotteet ja palvelut mahdollistavat käytönaikaisen sitoutuneen pääoman sekä tiedon hyödyntämisen älykkäästi. Se tuo mukanaan suuria muutoksia julkisen talouden ja yritysten tuottavuuteen, liiketoimintamalleihin, johtamisen käytäntöihin sekä vallitsevaan kilpailuun uusista markkinoista ja asiakkuuksista. Todennäköisesti muutokset eri aloilla ovat vaikutuksiltaan hyvinkin merkittäviä ja verrattavissa esimerkiksi pankkisektorin digitalisaatioon 1990-luvulla. Keskeistä on kuitenkin kysymys, miten digitaalisuuden ja Teollisen internetin yhteisvaikutus laajemmin tulee näkymään eri toimijoiden kentässä ja instituutioissa. (Suomi – Teollisen Internetin Piilaakso 2015, 7.)

Gartner ICT-alan tutkimus- ja konsultointiyrityksen ennusteen mukaan vuonna 2015 noin 4,9 miljardia laitetta on liitetty verkkoon, kun vuonna 2020 vastaava lukumäärä tulee olemaan jopa 25 miljardia laitetta. Tämä tarkoittaa noin viittä laitetta maailman jokaista asukasta kohden. (Quva & Elisa Oyj 2015, 3.)

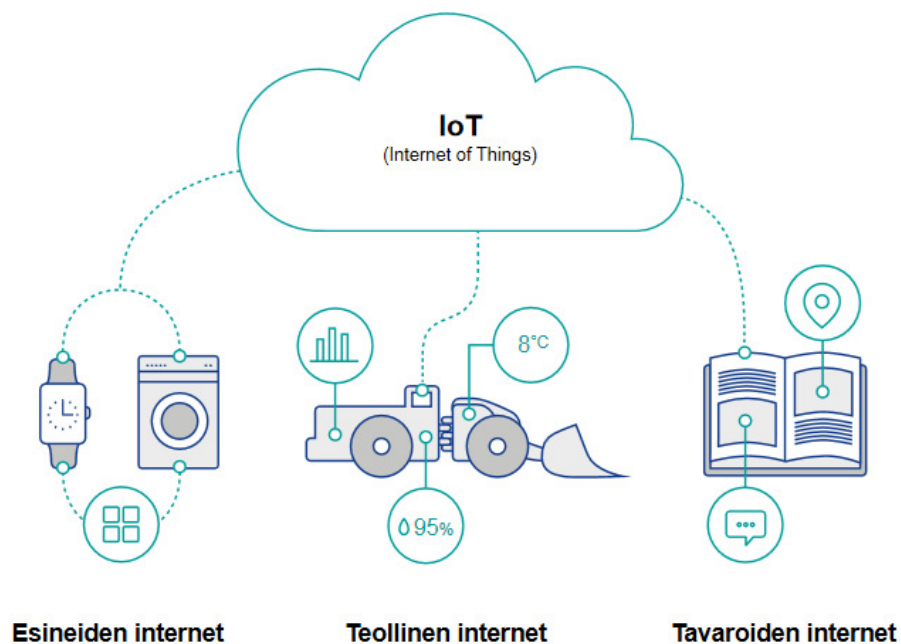
Gartnerin määritelmän mukaan teollisessa internetissä on kyse fyysisistä laitteista, jotka kykenevät havaitsemaan ympäristöään ja viestimään tai toimimaan kokemansa perusteella älykkäästi. Tähän tarvitaan paljon erilaisia antureita, ohjelmistoja sekä tietoliikenneyhteys, jolloin sensorit, koneet, prosessit ja palvelut tuottavat jatkuvasti niin sanottua big dataa, jota jalostamalla voidaan muun muassa ennakoida ja automatisoida työvaiheita. (Quva & Elisa Oyj 2015, 4.)

Aiemmin eri teknologiat, kuten prosessointiteho, verkkoyhteydet ja datavarastojen koko eivät mahdollistaneet datan automaattista ja reaaliaikaista jalostamista. Nykyisin tähän on olemassa tämän kaiken mahdollistava teknologia. (Quva & Elisa Oyj 2015, 9.)

Murros tulee olemaan uhka niille yrityksille, jotka pysyvät liian pitkään vanhoissa toimintatavoissa. Toisaalta se on mahdollisuus niille, jotka uskaltavat hyödyntää uutta teknologiaa keksien asiakkaita kiinnostavaa tarjontaa, tuottavuutta lisääviä toimintatapoja ja uusia voittoa tuottavia liiketoimintaratkaisuja. (Suomi – Teollisen Internetin Piilaakso 2015, 7.)

Etädiagnostiikkaa hyödyntää tällä hetkellä noin 40 % teollisuusyrityksistä, kun vastaava luku on noin 65 % energia-, vesi- ja jätehuollon sekä terveydenhuollon laitteiden kohdalla. Vaikuttaa siltä, että teollisuusyrityksissä suhtaudutaan ohjelmistopohjaiseen tekemiseen edelleen varsin konservatiivisesti. (Quva & Elisa Oyj 2015, 6.)

IoT voidaan käsitteenä jakaa eri osa-alueisiin kuvan 8 mukaisesti. Esineiden internetillä tarkoitetaan älykkäitä esineitä, jotka pystyvät kommunikoimaan internetin välityksellä joko keskenään tai pilvisovellusten kanssa. Teollinen internet sen sijaan tarkoittaa älykkäitä laitteita, jotka keräävät ja välittävät sensoreidensa avulla tietoa muun käytöstä ja olosuhteista, tavoitteena liiketoiminnan tehostaminen. Tavaroiden internet käsittää yksittäisiä tavaroita, joilla on internetissä oma identiteettinsä, vaikkeivät ne muuten olisi älykkäitä. Tavara voi olla esimerkiksi kirja tai lapanen, johon viitataan individuaalisen tunnisteen avulla. (Quva & Elisa Oyj 2015, 4.)




KUVA 8. IoT jaettuna eri osa-alueisiin (Quva ja Elisa Oyj 2015, 4, muokattu)

3.2 Koneoppiminen

Tässä luvussa on tarkoituksena tuoda esille yleisellä tasolla, mitä on koneoppiminen, mitä eri menetelmiä se pitää sisällään ja miten ne eroavat toisistaan. Yleisimmin käytettyjä koneoppimisen tyyppejä ovat ohjattu ja ohjaamamaton oppiminen. Ohjatussa tiedetään ennalta haluttu tulos ja ohjaamattomassa ei ole määritelty lopputulosta. (Brownlee 2016.) Tässä työssä esitellään vain ohjattua oppimista muutaman algoritmityyppin avulla.

Koneoppiminen on tekoälyn osa-alue, joka voidaan luokitella alaksi, jonka tarkoituksena on luoda algoritmeja, jotka vaativat empiiristä dataa, kokemusta ja koulutusta. Näin ollen ne pystyvät mukautumaan muutoksiin sekä kehittymään halutulla tavalla. Koneoppiminen sisältää osia muun muassa psykologiasta, filosofiasta, tilastotieteistä ja neurobiologiasta kuten kuvassa 9 on esitetty. (Kapitanova & Son 2012, 3–4.)



KUVA 9. Koneoppiminen koostuu monesta eri osa-alueesta (Kapitanova & Son 2012, 4)

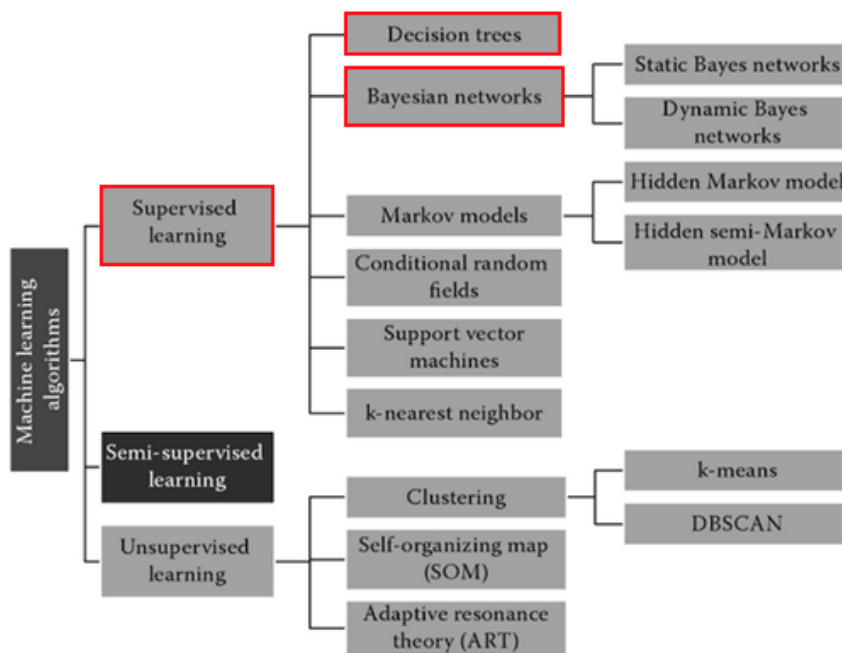
Koneoppiminen on Kapitanovan ja Son (2012, 4) mukaan kokoelma algoritmeja jotka pystyvät mukautumaan muutoksiin halutulla tavalla. Tämä saavutetaan luomalla opeteludataa, jossa on tiedossa syöte eli alkutila ja haluttu lopputulos. Tätä dataa käyttämällä voidaan luoda algoritmi, joka päättyy aina samaan lopputulokseen kaikilla samankaltaisilla syötteillä. Esimerkkinä tällaisesta toiminnasta on roskapostisuodatin, jonka tulisi tunnistaa erityyppiset roskapostit opetetun datan perusteella, vaikka ne olisivatkin sisällöltään hieman poikkeavat.

3.2.1 Algoritmit

Opinnäytetyössä käytetään Microsoft Azure ML palvelua, jonka toiminta pohjautuu älykkäisiin algoritmeihin. Jotta koneoppiminen on ylipäättään mahdollista, on sille ensin luotava algoritmit eli ohjelmoidut käskysarjat, jotka mekaanisesti seuraavat ohjelmoijan sille antamia käskyjä. Ohjelmointi kuitenkin noudattaa tiettyjä sääntöjä ja luonnonlakeja, joten ohjelmia ei voida kirjoittaa miten ja millaisia tahansa. Algoritmit voidaan kuitenkin toteuttaa monilla eri ohjelmointikielillä, sillä niiden kuvaamat ideat ja toimintatavat eivät riipu kielestä. (Kokkarainen & Ala-Mutka 2002, 15.)

Algoritmi on toteutettava niin, että se täyttää tietyt vaatimukset. Ensinnäkin sen on kuvattava tehtävän ratkaisemiseksi otettavat askeleet hyvin yksikäsitteisesti, että joka tilanteessa on selvää, mitä seuraavaksi tulisi tehdä. Algoritmin toinen vaatimus on oikeellisuus, eli sen on suoritettava vaadittu ratkaisu kaikille oletetuille tehtävän määrittelyn sallimille syötteille. Algoritmi ei myöskään saa koskaan joutua tilaan, jossa se joutuu ikuisen laskentaan, jossa ei ole ratkaisua. (Kokkarainen & Ala-Mutka 2002, 26.)

Alla olevassa kuvassa 10 on ohjattujen ja ohjaamattomien algoritmien eri tyyppejä. Tässä työssä esitellään ohjatuista tyypeistä päätöspuut (eng. Decision trees) ja Bayes-verkot (eng. Bayesian networks).

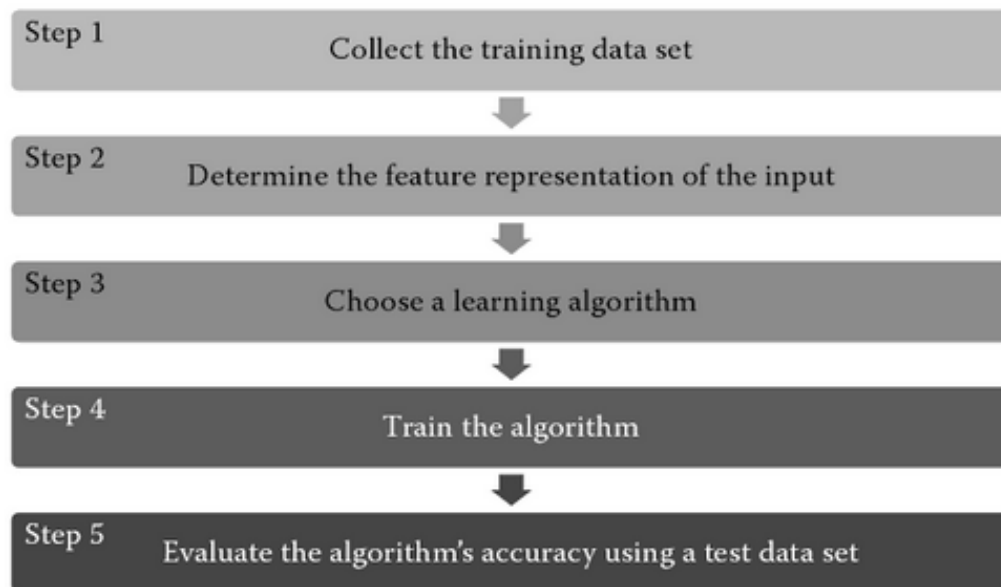


KUVA 10. Koneoppimisessa useimmiten käytetyt ohjatut (eng. supervised) ja ohjaamattomat (eng. unsupervised) algoritmit (Kapitanova & Son 2012, 6, muokattu)

3.2.2 Ohjattu oppiminen

Ohjatulla oppimisella (eng. supervised learning) tarkoitetaan algoritmeja, joille annetaan oppimisdataa ja joiden lopputulos on tiedossa (eng. labeled data). Oppimisdatan avulla algoritmia eli käskysarjaa voidaan kehittää niin, että sen on mahdollista saavuttaa haluttu lopputulokset tietynkaltaisella syötteellä. Ohjatussa oppimisessa järjestelmällä on niin sanottu ystävällismielinen opettaja, joka kertoo mitä järjestelmän tulisi tehdä kussakin tilanteessa. Ohjattu koneoppiminen on nimensä mukaisesti ihmisten ohjaamaa oppimista. (Kokkarainen & Ala-Mutka 2002, 320–321.)

Kuvassa 11 on esitetty ohjatun oppimisen tavanomainen työnkulku. Ensimmäisessä vaiheessa kerätään koulutusdataa, jonka sen jälkeen luokitellaan. Tämän jälkeen valitaan algoritmityyppi sen mukaan millaista dataa on käytettävissä ja millaisia virheitä siinä voi esiintyä. Sitten algoritmia koulutetaan datan avulla ja katsotaan millaisia tuloksia saadaan. Lopuksi algoritmillemme syötetään aivan uutta dataa ja testataan toiminnan oikeellisuutta. Tulokset tarkastetaan ja tarvittaessa algoritmia opetetaan lisää kunnes saavutetaan haluttu lopputulos. (Kapitanova & Son 2012, 6–7.)




KUVA 11. Ohjatun oppimisen vaiheet (Kapitanova & Son 2012, 6, muokattu)

3.2.3 Bayes-verkot

Bayes-verkot ovat niin sanottuja päättelyjärjestelmiä, jotka pohjautuvat vanhaan ja koettuun todennäköisyyslaskentaan. Tämä siis tarkoittaa, että kaikille mallituksen elementeille, arkkitehtuurille, sovitettaville parametreille ja sovitukseen käytetylle datalle oletetaan todennäköisyysjakaumat. Tämän jälkeen valitaan malli ja parametrit, jotka ovat kaikkein todennäköisimmät. Malli sallii kuitenkin asiantuntijan tietämyksen käyttämisen, koska hän voi kokemuksensa perusteella valita erilaisten mallien ja parametrien etukäteistodennäköisyydet eli priorit. Vaikeutena on toisaalta, että todennäköisyyden tarkastelutapa voi olla liian yleinen. Suurta joukkoa todennäköisyysjakaumia on hankala arvioida ja niitä yhdistäviä hyvin moniulotteisia integraaleja on vaikea laskea. Tällöin joudutaan turvautumaan voimakkaisiin yksinkertaistuksiin. Kuitenkin esimerkiksi luokittelussa yksinkertaisetkin mallit ovat osoittautuneet hyvin tehokkaiksi ja toimiviksi. (Myllymäki & Tirri 1998, iv.)

Bayes-verkko esittää joukon satunnaismuuttujia ja niiden välisiä ehdollisia riippuvuuksia suunnatun syklittömän verkon avulla. Verkon solmut edustavat satunnaismuuttujia ja kaaret niiden välisiä riippuvuuksia. Jokaiseen solmuun liitetään ehdollinen todennäköisyysfunktio, jonka määräämä jakauma vastaavan muuttujan arvoille riippuu solmun vanhempien saamista arvoista. Bayes-verkot ovat hyvin sopeutuvaisia ja sopivat täten koneoppimisen sovelluksiin. (Kapitanova & Son 2012, 6-7.)

Bayes-verkot ovat pohjimmiltaan melko yksinkertaisia suunnattuja syklittömiä verkkoja eli sellaisia joiden alkupisteeseen ei pääse palaamaan. Bayes-verkot toimivat syyseuraussuhteella, joiden lopputulokseen vaikuttaa todennäköisyys. Esimerkissä (kuva 12) on kuvattuna tilanne, jossa henkilö menee kotiin yöllä, mutta haluaa tietää onko perhe kotona ennen kuin hän avaa oven. Yleensä kodin ulkopuolella on valo päällä, mikäli perhe on lähtenyt muualle. Lisäksi koira on ulkona takapihalla, jos muut perheenjäsenet ovat poissa. Sama tilanne toistuu, mikäli koiralla on vatsavaivoja. Tällaisia graafeja voidaan käyttää myös ennustamaan mitä tapahtuu, jos koira ja perhe menevät ulos. (Charniak 1991, 51.)



KUVA 12. Bayes-verkon esimerkki syy-seuraussuhteista (Charniak 1991, 51, muokattu)

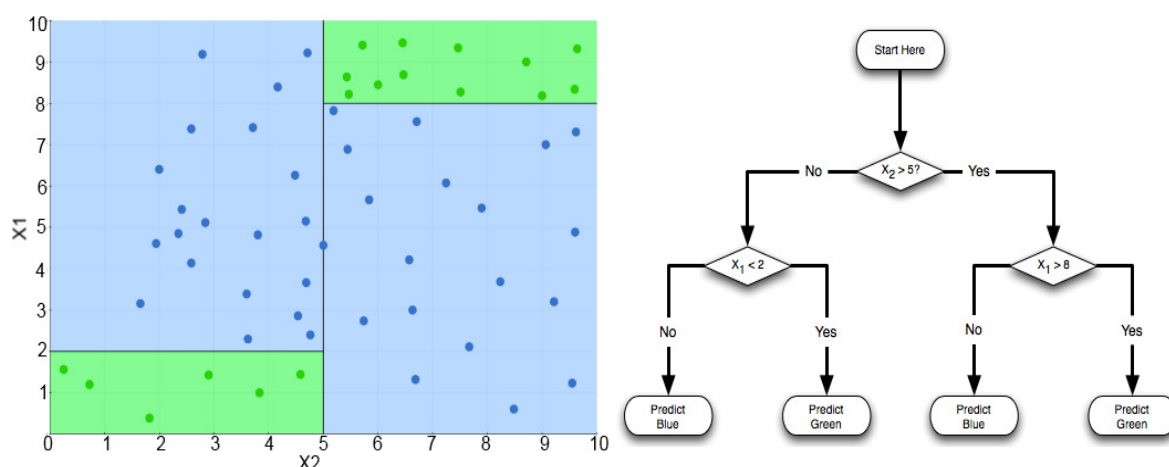
On tärkeää muistaa, että tällaiset syy-seuraussuhteet eivät ole absoluuttisia, eli joskus voi unohtua laittaa valo päälle tai koira jää sisällä perheen lähtiessä ulos. Tämän kaltaisia, mutta huomattavasti laajempia graafeja voidaan käyttää koneoppimisessa ja päätöksenteossa. Koneoppimisen osalta Bayes-verkkoja käytetään etenkin silloin, kun halutaan kerätä tietoa tuntemattomasta systeemistä. (Charniak 1991, 51.)

3.2.4 Päätöspuut

Päätöspuuta voi verrata vuokaavioon, jossa edetään selkeästi valintojen kautta päätökseen. Päätöspuu on nimensä mukaisesti puurakenne, jonka kuhunkin sisäsolmuun liittyy jokin attribuuttitesti ja jonka jokaisessa lehtisolmussa on jokin luokittelu (Kokkarainen & Ala-Mutka 2002, 316).

Päätöspuu saa alkunsa juurisolmusta, joka sisältää kaikki havainnot käsiteltävästä aineistosta. Juurisolmun muuttuja on nimeltään analyysin kohdemuuttuja. Puuta alaspäin tarkasteltaessa havainnot luokittelevat täydellisesti poissulkeviin joukkoihin. Puunkasvatusalgoritmista riippuen jako voidaan tehdä kahteen tai useampaan haaraan. Jokaiseen jakautumiskohtaan liittyy muuttuja, jonka perusteella jako on suoritettu sekä muuttujan arvoalue kullekin haaralle. Puun alimpia solmuja kutsutaan päätössolmuiksi. Päätössolmut kuvaavat, miten aineisto jakautuu luokkiin sääntöjä soveltamalla juurisolmun ja jokaisen puussa olevan päätössolmun välillä. Päätöspuut tuottavat näin ollen helposti tulkittavia malleja. (Partanen 2001.)

Kuvassa 13 on esimerkki päätöspuusta, jossa luokittelu alkaa juurisolmusta syöttämällä arvo X_2 . Tämän jälkeen se haarautuu arvon mukaisesti kunnes päätösolmu saavutetaan, joka on ennustettu tulos. (CIS 520 Machine Learning 2016.)



KUVA 13. Esimerkki päätöspuusta ja arvon luokittelusta (CIS 520 Machine Learning 2016, muokattu)

3.2.5 Esimerkkejä koneoppimisen käytännön sovelluksista

Nykyään on vaikea olla törmäämättä algoritmeihin jokapäiväisessä digitalisoituneessa elämässä. Mahdollisuuksia koneoppimisen hyödyntämiseen on lukemattomia, ainoastaan mielikuvitus ja verkkoyhteyksien toimivuus on rajoitteena. Lukiessasi esimerkiksi tuotteiden käyttäjäarvosteluja, etsiessäsi hakukoneen avulla reseptiä tai katsoessasi elokuvia internetissä, olet jatkuvasti kanssakäymisessä algoritmien kanssa.

Joistakin erittäin kehittyneistä algoritmeista on tullut suorastaan legendaarisia, esimerkkinä Googlen kehittämä PageRank, joka määrittelee verkkosivustojen sijoituksen hakutuloksissa. Tähän siis perustuu Googlen idea hakukoneen toiminnasta, joka nostaa eniten linkitetyn tuloksen hakulistan kärkeen. Kuitenkin kaikki algoritmit ovat pohjimmiltaan vain vaiheittainen kuvaus siitä, miten jokin asia lasketaan, ongelma ratkaistaan tai data käsitellään. (Innovations 2014.)

Analyttisillä menetelmillä voidaan jalostaa tietoa, nähdä vaikutuksia ja luoda ennusteita tulevast. Nykyään on useita yrityksiä, jotka hyödyntävät ennakoivaa analytiikan tekniikkaa ja ovat sen avulla pystyneet tehostamaan liiketoimintaansa. Verkkokaupassa on

saatu ylivoimaista myynnin osuvuutta tarjoamalla asiakkaalle täsmälleen oikeita tuotteita ja palveluita juuri oikea-aikaisesti. (Quva ja Elisa Oyj 2015, 11-12.)

Koneoppiseen perustuvia algoritmeja on yritetty kehittää myös pörssikurssien kehityksen ennustamiseen. Ilmiö on monimutkainen, sillä siihen vaikuttavat tekijät ovat moninaisia, mutta toisaalta selkeän numeerisia. Ennustettava ilmiö, pörssi-indeksin kehitys, on selkeä, mitattava ja yksiselitteinen. Teknisessä mielessä tämä olisi mitä otollisin haaste neuroverkoille. Lisäksi onnistunut ennuste tuottaisi merkittävää rahallista hyötyä. (Nyman 2013.)

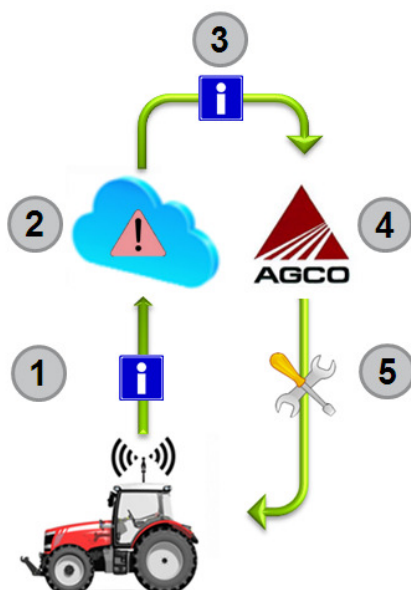
Suomessa aiotaan ottaa käyttöön sähköinen terveyskeskus vuonna 2018. Hoidon tarvetta arvioiva koneäly päättelee algoritmeja käyttäen, voiko potilas hoitaa vaivaansa itsenäisesti. Tarkoituksena on, että asiakas kirjautuu sähköiseen palveluun ja vastaa annettuihin kysymyksiin. Vastauksista ja henkilön taustatiedoista riippuen älykäs algoritmi ohjaa potilasta joko hoitamaan vaivaansa itsenäisesti tai varaamaan ajan lisätutkimukseen terveydenhuollon ammattilaiselle. (Elo 2016.)

4 KONEOPPIMISEN HYÖDYNTÄMINEN VIKADIAGNOSTIIKASSA

4.1 Esitys uudesta vikadiagnostiikan toimintamallista

Nykyinen työkonien vikadiagnostiikka ei mahdollista ennakoivaa vikojen havainnointia. Alla olevassa kuvassa 14 on esitetty periaatetasolla millainen uusi toimintapa voisi olla tulevaisuudessa, jossa viat havaittaisiin ja korjattaisiin ennen kuin käyttäjä edes huomaa työkonessa vikaa.

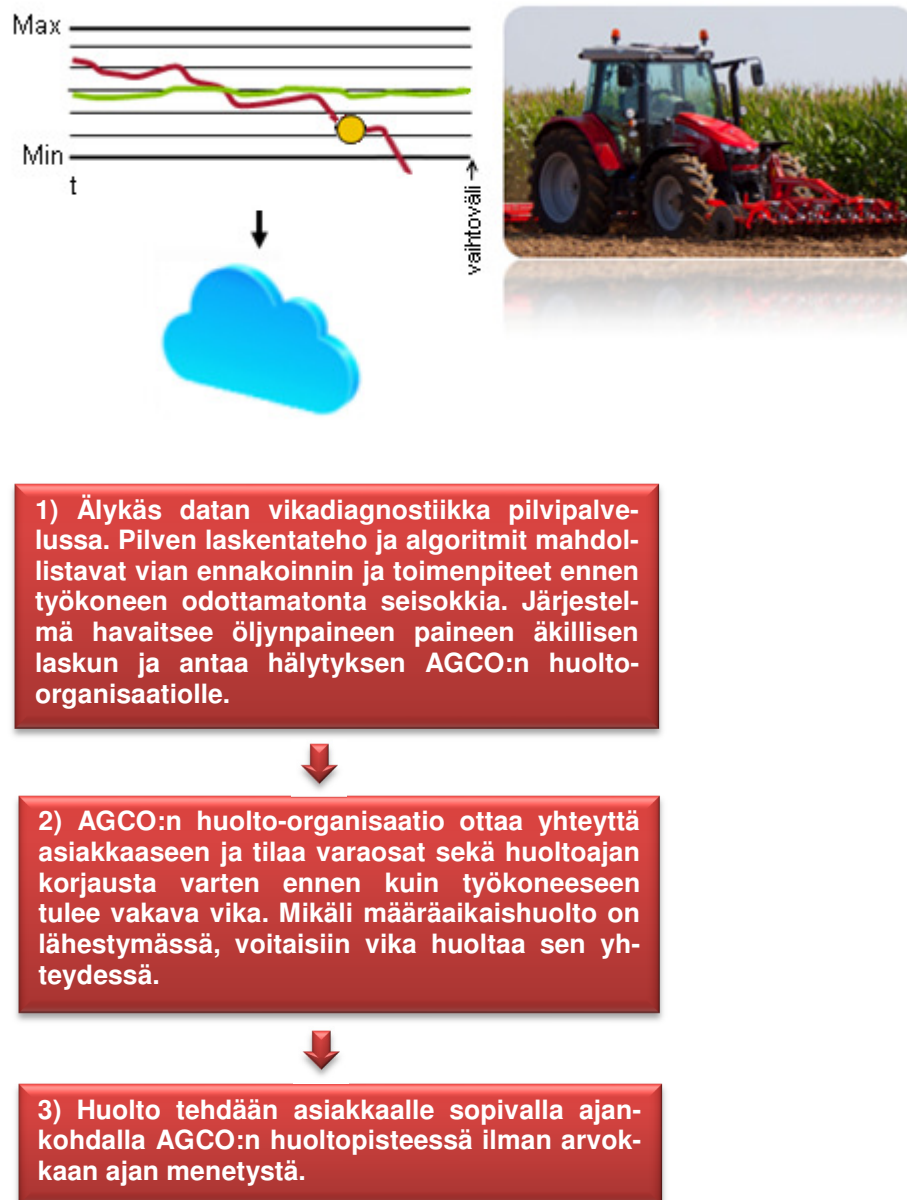
- 1) Työkone syöttää jatkuvasti mobiili- tai satelliittiverkon kautta anturitietoa käytöstä ja olosuhteista pilvipalveluun automaattisesti prosessoitavaksi.
- 2) Pilvipalvelun suorituskyky mahdollistaa tietojen jatkuvan analysoinnin algoritmien avulla. Tiedoissa havaitaan normaalista käytöksestä poikkeavaa sensoridataa, jonka epäillään johtavan vikaantumiseen. Vikakoodia ei kuitenkaan näytetä työkonen kuljettajalle tässä vaiheessa.
- 3) Tieto potentiaalisesta viasta lähetetään eteenpäin AGCO:n huolto-organisaation asiantuntijoiden varmistettavaksi.
- 4) AGCO:n huolto-organisaation ekspertit tutkivat dataa tarkemmin pidemmältä aikaväliltä ja tekevät sen perusteella päätöksen vaihtaa komponentin, jonka suorituskyky on heikentynyt merkittävästi.
- 5) Asiakkaaseen otetaan yhteys ja huolto suoritetaan ennen työkonen ennakoimatonta seisakkaa.



KUVA 14. Tulevaisuuden vikadiagnostiikan toimintamallin periaatekuva

4.2 Ennustavan vikadiagnostiikan kehitys öljynpaineen seurantaan

Uuteen toimintatapaan viitaten, kuvassa 15 on esitetty tarkemmin miten moottorin öljynpaineen vikadiagnostiikan on ajateltu tapahtuvan pilvipalvelua hyödyntäen. Keltainen pallo edustaa hetkeä, jolloin pilvipalvelu lähettää tiedon analysoitavaksi huolto-organisaatiolle. Öljynpaineessa havaitaan äkillinen muutos (punainen linja) verrattuna normaaliin käytökseen (vihreä linja). Pilvipalvelu antaa hälytyksen eteenpäin analysoitavaksi. Tällaista tapaa noudattaen vika voitaisiin korjata ennen kuin moottorin ohjausyksikkö ECU sytyttää kojetaulun vikavalon ja pahimmassa tapauksessa pysäyttää moottorin, mikäli paine jatkaa laskuaan. Ennustavan vikadiagnostiikan kehitys ja siihen liittyvät algoritmit pyritään kouluttamalla havaitsemaan muutokset paineessa.



KUVA 15. Uusi öljynpaineen vikadiagnostiikan toimintamalli

On syytä muistaa, että voiteluöljyn tulee olla lähtökohtaisesti AP:n määrityksen mukaista, jotta se toimisi oikein. Öljyn viskositeetti vaihtelee lämpötilan mukaan, joten väärän viskositeetin omaava öljy ei kykene voitelemaan komponentteja kaikissa olosuhteissa. Mikäli öljyllä on korkea viskositeetti eli se on paksua, niin kesäolosuhteissa toiminta voi olla moitteetonta, mutta talvella lämpötilan ollessa alhainen, se ei pysty voitelemaan komponentteja kunnolla. Koneoppimisen algoritmit eivät välttämättä osaa huomioida tällaisia ongelmia. On siis pyrittävä poistamaan erikoisemmat vian aiheuttajat, jotta algoritmit osaavat varoittaa ongelmista oikein.

4.2.1 Koneoppimispalvelun valinta

Koneoppimispalveluita on viime vuosina ilmestynyt useampia ja tässä luvussa pohditaan yleisimmin käytettyjen toimijoiden joukosta parasta mahdollista vaihtoehtoa AP:lle automaattiseen vikadiagnostiikkaan. Palvelun maksullisuuteen ei oteta kantaa.

Koneoppimispalveluita ovat lähteneet kehittämään suuret yritykset kuten Google, Microsoft, IBM ja Amazon. Ne ovat pyrkineet tekemään palveluistaan mahdollisimman helppokäyttöisiä, eikä käyttäjän tarvitse syvällisemmin tuntea teorioita tai koodausta yksinkertaisia ennustuksia tehtäessä. Jotkut yritykset kylläkin antavat mahdollisuuden algoritmien yksityiskohtaiseen muokkaukseen.

Vertailen tässä lyhyesti isoista toimijoista IBM Watson Analytics ja Microsoft Azure Machine Learning palveluja. Jälkimmäinen vaihtoehto eli Microsoft Azure ML tarjoaa kattavan valikoiman valmiiksi rakennettuja moduuleja koneoppimisprosessin jokaiseen vaiheeseen. Moduuleita pystyy tarvittaessa räätälöimään haluamakseen ja R- tai Python-koodin lisääminen onnistuu prosessin eri vaiheissa. R-ohjelmointikielen kehittyneillä tilastollisen analyysin ominaisuuksilla, sekä kattavalla valikoimalla valmiita paketteja, voidaan tuoda lisäarvoa koneoppimismallin hiomiseen. Azure ML:n ollessa osa Microsoftin pilvipalvelua, on tiedon integrointi eri sovellusten välillä kustannustehokasta. Lisäksi pilveen rakennettu analysointiprosessi on nopea ja turvallinen. (Tauriainen 2015.)

Azure ML on tarkoitettu erityisesti prediktiviseen eli ennakoivaan analytiikkaan ja aineistojen yhdistämiseen. IBM Watson Analytics sen sijaan painottuu enemmän tutkivaan aineiston analysointiin. Käyttäjän on siis tunnettava vähintään perusperiaatteet ennustamisesta ja aineiston mallintamisesta IBM Watsonia käytettäessä ennen kuin sitä pystyy täysin hyödyntämään ennustamistarkoituksessa. (Liukkonen 2016.)

Koneoppimispalveluiden ominaisuuksia vertailtaessa valitsen näin ollen Microsoftin vaihtoehdon, koska se on tarkoitettu nimenomaan ennustavaan analytiikkaan, eikä vaadi pitkällistä kokemusta koodaamisesta tai algoritmeista. Lisäksi AP:n käyttämällä ohjelmistotalolla on kokemusta Azuresta, joten sen opettelu se voi olla hyödyksi jatkokehitystä ajatellen.


4.2.2 Algoritmimallin valinta

Todenmukaisen algoritmin avulla voitaisiin automaattisesti seurata työkonoiden öljynpaineita pilvipalvelussa ja vaikuttaa moottorin toimintavarmuuteen sekä asiakastyytyväisyyteen. Onkin siis tärkeää valita oikeanlainen algoritmi, joka pystyy ennakoimaan vikaantumiset moottoridatasta. Kuten aiemmin todettiin mitä vähemmän on parametreja analysoitavana, sen tarkempaa on ennustaminen.

Taulukossa 2 on lueteltuna muutamia Microsoft Azure ML koneoppimispalvelussa valittavissa olevia algoritmimalleja. Siitä nähdään, että regressiomallinen ohjattu algoritmi soveltuu parhaiten numeeriseen ennustukseen, jota siis tarvitaan myös öljynpaineen seuraamiseen. Tarkemmin sanottuna ennustamiseen sopii lineaarinen regressio (kuva 16), jossa y-akselin muuttuja riippuu lineaarisesti muuttujista x-akselilla. Tätä algoritmityyppiä voidaan harkita käytettävän tulevaisuuden malleissa. Yhtenä mielenkiintoisena lisävaihtoehtona olisi Bayes-verkkoon pohjautuva lineaarinen regressiomalli, jonka avulla voisi tutkia useampien parametrien vaikutusta ennusteeseen.

TAULUKKO 2. Microsoft Azure ML:n koneoppimismenetelmät jaettuna algoritmial-
lin päätyypin mukaan (Tauriainen 2015, muokattu)

Malli	Tarkoitus	Käyttökohde
Luokittelu (Classification)	Luokitellaan kohde ennalta määrät- tyihin kahteen tai useampaan kategoriaan.	-Kohdennettu markkinointi asiakas- tyypin ja olosuhteiden perusteella -Kuvan tunnistaminen
Ryhmittely (Clustering)	Analysoidaan luokittelematon data ja tunnistetaan siitä erilaiset ryh- mät.	-Asiakaskannan ryhmittely pysyvien ja vaihtuvien muuttujien perusteella -Nettisivustojen/dokumenttien sisäl- lön analysointi
Regressio (Regression)	Numeerisen arvon ennustaminen.	-Kannattavuuden kehityksen ennus- taminen -Asiakassuhteen keston ennakoiti -Teollisuuskoneen huoltoajankohdan ennakoiti
Suosittelu (Recommendation)	Arvioidaan mistä tuotteista asiakas pitää.	-Verkkokaupan ostosuositukset -CRM:n up- ja cross-sell suositus asiakkaalle -Intranetin suositellut sisällöt, esi- merkiksi dokumentit tai keskustelut
Poikkeamien etsiminen (Anomaly Detection)	Löydetään selvästi normaalista poikkeava data aineistosta.	-Laitteistojen lokien tarkkailu ja toi- menpidesuosituksen tuottaminen -Luottokorttien väärinkäytön havait- seminen



KUVA 16. Arvon ennustaminen lineaarisen regression avulla (Rohrer 2016)

4.2.3 Demovaihe

Demovaiheessa testataan valittua algoritmia Microsoft Azure ML Studio palvelussa (<https://studio.azureml.net/>) ja tarkastellaan pystyykö sen avulla ennustamaan viat moottorin öljynpaineessa. Microsoftin palvelu on rakennettu hyvin käyttäjäystävälliseksi ja sieltä löytyy paljon esimerkkejä erilaisten algoritmityyppien käytöstä. Kuitenkin käyttäjillä tulee olla jonkin verran kokemusta koneoppimisen ja algoritmien perusteista.

Algoritmien koulutus ja validointi tehdään graafisen käyttöliittymän avulla, jossa muun muassa määritellään käytettävä algoritmi ja siihen vaikuttavat parametrit. Käyttäjän tulee rakentaa prosessiketju, jossa eri operaatioita linkitetään toisiinsa loogisessa järjestyksessä. Prosessiketjun luonti on kohtalaisen helppoa drag & drop-menetelmällä, jopa ensimmäisellä käyttökerralla. (Liukkonen 2016.) Alla on lyhyesti kuvailtuna vaiheet, jotka käyttäjän tulee tehdä:

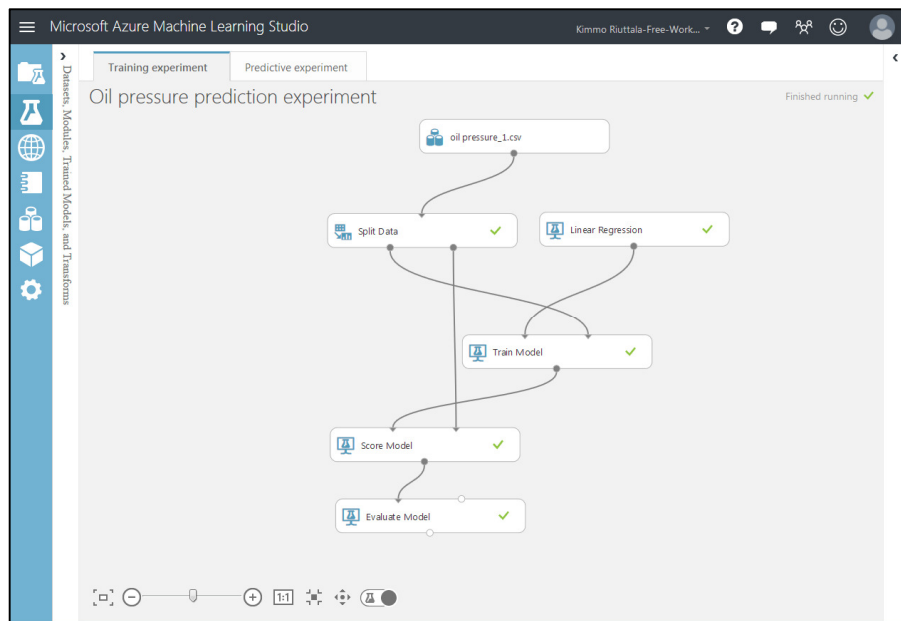
1. Vaihe - Datan lataus: Palveluun ladattiin esimerkkidata csv-muodossa (taulukko 3), jossa oli tietoa työkoneiden moottoreiden keskimääräisistä öljynpaine-arvoista päivittäin tyhjäkäynnillä. Datassa oli mukana myös koulutusaineistoa viidennen päivän arvolle, jonka arvoa algoritmilla pyritään tässä tapauksessa ennustamaan.

TAULUKKO 3. Microsoft Azure ML palveluun ladattu data, jossa on moottorin öljynpaineen päivittäinen keskiarvo tyhjäkäynnillä

	Öljynpaineen keskiarvo tyhjäkäynnillä - päivä #1	Öljynpaineen keskiarvo tyhjäkäynnillä - päivä #2	Öljynpaineen keskiarvo tyhjäkäynnillä - päivä #3	Öljynpaineen keskiarvo tyhjäkäynnillä - päivä #4	Öljynpaineen keskiarvo tyhjäkäynnillä - päivä #5
Moottori 1	4	7	7	6	7
Moottori 2	6	4	3	1	1
Moottori 3	6	5	6	6	Tuntematon
Moottori 4	5	7	6	6	5
Moottori 5	5	7	6	6	Tuntematon
Moottori 6	6	7	7	6	6
Moottori 7	5	6	6	6	6
Moottori 8	5	6	6	4	Tuntematon
Moottori 9	6	6	5	6	6
Moottori 10	7	4	3	2	Tuntematon

2. Vaihe – Algoritmimallin määrittäminen: Palvelussa on monia eri algoritmimalleja valittavana, mutta tässä sopivaksi todettiin lineaarinen regressiomalli. Sen avulla saadaan luotua numeerisia ennustuksia viidelle päivälle.

3. Vaihe – Algoritmin koulutus: Koulutusta varten lisättiin 'Train Model' operaatioelementti sekä 'Split Data', jonka avulla kerrotaan, että osa ladatusta aineistosta on testaukseen ja toinen osa koulutukseen. Prosessiin olisi mahdollista lisätä myös optimointielementtejä, kuten 'Tune Model Hyperparameters', jolla vaikutetaan ennustettaviin arvoihin, mutta tässä se jätettiin pois, jotta mallista saataisiin yksinkertainen. Kuvassa 17 on esitys valmiista prosessiketjusta, jonka mukaan algoritmi tekee datasta päättelyt ja ennustukset.



KUVA 17. Öljynpaineen ennustamiseen tehty prosessiketju Microsoft Azure ML palvelussa

4. Vaihe – Toiminnan ja ennustuksen arviointi: Algoritmimallin ennustuksen arvoja voidaan tarkastella 'Score Model' elementin avulla. Tuloksista nähdään, että tuntemattomille viidennen päivän arvoille on järjestelmä luonut numeeriset arvot perustuen koulutusdataan. Ennustusarvot näkyvät 'Scored labels' kohdassa kuvassa 18.

Microsoft Azure Machine Learning Studio

Kimmo Riuttala-Free-Work...

?

💬

👤

🔄

👤

Dataset, Model, Trained Model, and Transform

Training experiment

Predictive experiment

Oil pressure prediction experiment > Score Model > Scored dataset

rows

columns

10

6

view as

Oil pressure average
at idle day 1

Oil pressure average
at idle day 2

Oil pressure average
at idle day 3

Oil pressure average
at idle day 4

Oil pressure average
at idle day 5

Scored
Labels

4

7

7

6

7

7.109583

6

4

3

1

1

1.66395

6

5

6

6

4.995242

5

7

6

6

5

6.201522

5

7

6

6

6.201522

6

7

7

6

6

6.30106

5

6

6

6

6

5.800513

5

6

6

4

5.232959

6

6

5

6

6

4.892452

7

4

3

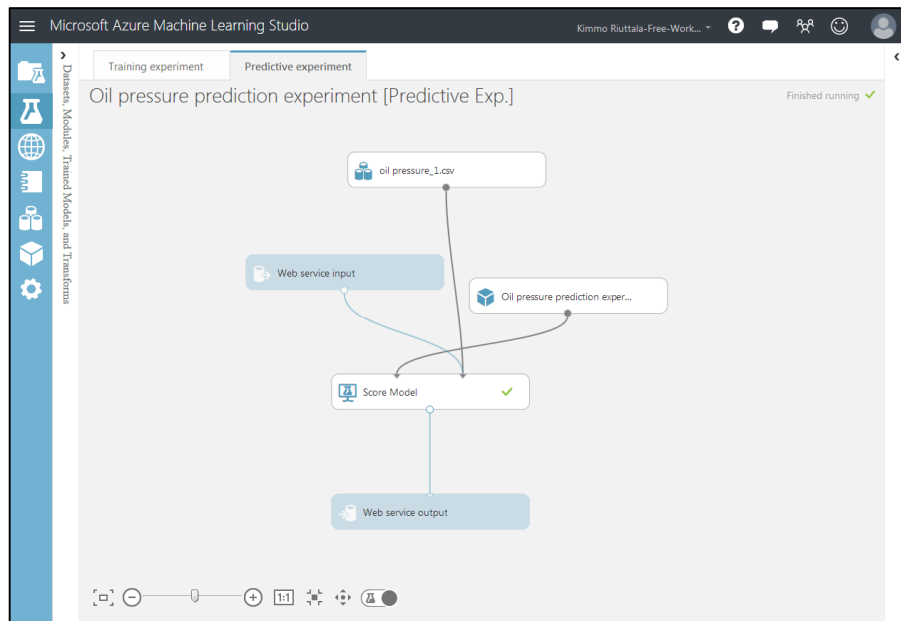
2

1.543465

Statistics and Visualizations

KUVA 18. Algoritmin koulutuksen jälkeinen tuloksien tarkastelu

5. Vaihe – Algoritmimallin testaus: Algoritmimallin lopullinen testaus tapahtuu Microsoft Azuren internet-palvelussa 'Predictive experiment' välilehdellä, johon Azure tekee automaattisesti hieman muutoksia prosessiketjuun (kuva 19).

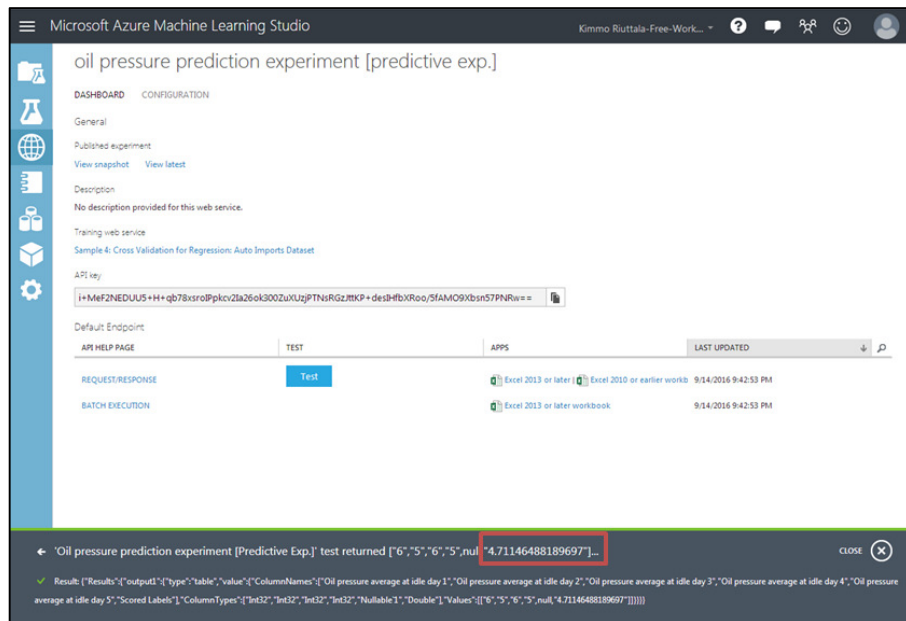


KUVA 19. Internet-palvelun versio prosessiketjusta

Internet-palvelun avulla voidaan tämän jälkeen ennustaa minkä tahansa numerosarjan jatkoa kuvitteelliselle viidennelle päivälle. Ensimmäisessä esimerkissä testattiin ennustettavuutta arvoilla: 1. päivä 6 - 2. päivä 5 - 3. päivä 6 - 4. päivä 5 (kuva 20). Viides päivä jätettiin tyhjäksi.

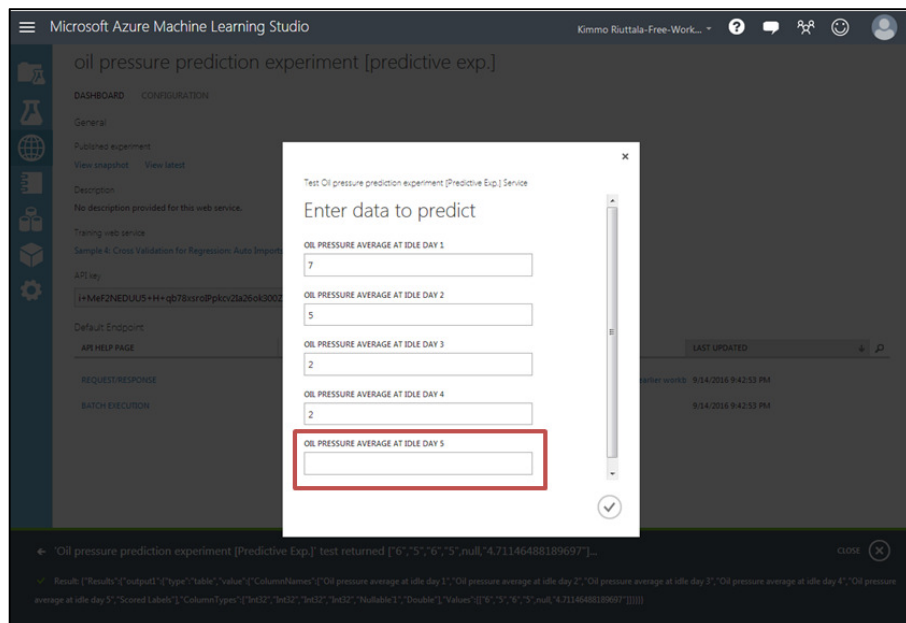
KUVA 20. Testaukseen syötetyt arvot, esimerkki 1

Näillä arvoilla palvelu antaa viidennen päivän tulokseksi pyöristettynä 4.7 (kuva 21). Tehtäessä viimeistelyä algoritmillemme, täytyy tulosta tietenkin verrata oikeaan öljynpaineen käyttäytymiseen, joka saadaan kenttätestien datasta.



KUVA 21. Algoritmimallin antama ennuste esimerkille 1: 4.7

Toisessa esimerkissä testattiin ennustettavuutta arvoilla: 1. päivä: 7 - 2. päivä 5 - 3. päivä 2 - 4. päivä 2 (kuva 22). Viides päivä jätettiin jälleen tyhjäksi. Näillä arvoilla algoritmin tulisi siis antaa laskeva ennuste.



KUVA 22. Testaukseen syötetyt arvot, esimerkki 2

ta. Mikäli on saatavilla runsaasti syötetietoa, niin on itse asiassa helppoa ennustaa erinomaisten tarkasti dokumentoitua tulevaisuutta, joka on aineistossa mukana. Ongelmana on vain se, että algoritmi pettää välittömästi, jos samaa ennustustapaa käyttää tulevaan päivään, jota aineistossa ei ole mukana. Ilmiö on samankaltainen kuin historian tulkitsemisessa. Jälkikäteen on helppoa määrittää syyt, miksi historia tapahtui niin kuin se tapahtui. On kuitenkin paljon vaikeampaa ennustaa tulevaisuutta tästä eteenpäin. Melkein minkä tahansa kohtuullisen runsaan aineiston perusteella on jopa äärettömän monta erilaista tapaa selittää se tulevaisuus, joka realisoitui aineistossa. On myös olemassa äärettömän monta väärää tapaa luulla ymmärtävänsä tietty ilmiö. Teoreetikot kutsuvat näitä selitystapoja ortogonaalisten funktioiden joukoiksi. (Nyman 2013.)

Kaikkeen ennustamiseen liittyy tietysti omat riskinsä ja koskaan ei voida luoda täysin varmaa algoritmia öljynpaineiden ennustamiseen. Tämän vuoksi täytyy edelleen käyttää asiantuntijoita, jotka analysoivat dataa ja tulkitsevat käyttäjän sekä olosuhteiden välisiä suhteita. Kuitenkin tämä olisi huomattavasti parempi toimintatapa kuin nykyinen, jossa tietoa loppuasiakkaiden moottoreiden öljynpaineista saadaan todella harvoin ja aivan liian myöhään, jotta ongelmiin voitaisiin puuttua ajoissa.

Microsoft Azure ML koneoppimispalvelun käyttö näin ensikertaiselle oli miellyttävä kokemus. Palvelusta löytyi paljon esimerkkejä, joita tutkimalla ja testaamalla löytyi sopiva malli numeeriseen ennustamiseen. Kuitenkin lopullisen algoritmin optimointi vaatii ekspertin apua. Azuren tulosten visualisointi sen sijaan kaipaa parannusta ja ei ollut aina selvää mikä tarkoittaa mitään. Vertailtaessa Microsoftin palvelua IBM Watson Analytics työkaluun voidaan sanoa, että Watson on business-käyttäjän työväline ja Azure ML data-analyytikon (Liukkonen 2016).













5 PALVELULIIKETOIMINNAN KEHITYS JA ETÄKUNNONVALVONNAN HYÖDYT SIDOSRYHMILLE

5.1 Teollisen internetin mahdollistamat uudet palvelut

Teollinen internet on tuonut uusia mahdollisuuksia kehittää yritysten liiketoimintamalleja, etenkin palveluiden suhteen. Asiakkaaseen voidaan olla yhteydessä lähemmin kuin koskaan aikaisemmin ja ongelmiin pystytään puuttumaan nopeasti. Lisäksi kentältä saadaan arvokasta tietoa tuotteiden todellisista käyttötilanteista tulevaisuuden kehitystä ajatellen. Positiivisia merkkejä on siis ilmassa kaikkien kannalta. Tarkoituksena on pohdita millaisilla toimilla voitaisiin tuottaa lisäarvoa asiakkaille ja miten AGCO hyötyisi uudesta teknologiasta.

Teollisen internetin tuottama lisäarvo pohjautuu pitkälti sen avulla kerättyyn ja tuotettuun tietoon. Todelliset uuden liiketoiminnan mahdollisuudet riippuvat siitä, miten yrityksillä käytettävissä oleva tieto saadaan jalostettua hyödynnettävään muotoon ja kuinka luodaan sellaista automaattista, reaaliaikaista analytiikkaa, joka valitsee ja järjestää valtavaa tietomassaa eli big dataa käyttökelpoisiksi tunnusluvuiksi ja tilannekuvauksiksi. Ennen kaikkea se antaa hyödyllistä tietoa yrityksen päätöksenteon tueksi. (Quva & Elisa Oyj 2015, 5.)

Uudet ratkaisut mahdollistavat uudenlaiset ansaintamallit, kuten kuvassa 24 on esitetty. Palvelukeskeinen liiketoiminta antaa yrityksille mahdollisuuden lisäpalveluihin ja uusiin tuotteisiin. Näitä voivat olla muun muassa erilaiset huoltopalvelut tai tuotteisiin ladattavat ohjelmistot. Esimerkiksi Rolls-Royce Plc oli yksi ensimmäisten teollisten yritysten joukossa, joka otti käyttöön uuden tuotos-pohjaisen liiketoimintamallin, jossa lentoyhtiöitä laskutetaan ”Power by the Hour” -periaatteen mukaisesti. (Quva & Elisa Oyj 2015, 4, 12.)

Perinteinen toimija		Teollista internetiä hyödyntävä toimija
Hidasta ja kallista 	Innovaatiot	Nopeaa ja kustannustehokasta 
Heikkenee ja investoinnit Suomessa vähenevät 	Kilpailukyky	Pysyy hyvänä ja Suomesta rakentuu houkutteleva investointikohde 
Reaktiivinen 	Palvelumalli	Proaktiivinen 
Tarjotaan tuote jota huolletaan tarvittaessa 	Tuotteet ja palvelut	Tuotetta päivitetään ja rikastetaan 
Data huollon ja kunnossapidon tukena 	Datan rooli	Data on tietoa, josta voi syntyä uusia liiketoimintamalleja 
Hierarkinen ja jäykkä 	Johtamis-kulttuuri	Osallistava ja läpinäkyvä 

KUVA 24. Teollisen internetin vaikutukset yrityksen toimintamalleihin (Quva & Elisa Oyj 2015, 7, muokattu)

5.2 Etäkunnonvalvonnan vertailuanalyysi

Vertailen tässä luvussa kahden valitsemani yrityksen etäkunnonvalvontapalveluita. Kävin henkilökohtaisesti kyselemässä tietoa muun muassa siitä, miten etäseurantaa hyödynnetään ja millainen on ollut asiakaspalaute. Wärtsilä Oyj:llä on pitkä kokemus tuotteidensa maailmanlaajuisesta etäseurannasta, joten se soveltui hyvin analysoitavaksi. Toinen yritys oli Komatsu Forest Oy, joka käyttää metsäkoneissaan AGCO Powerin moottoreita ja lanseerasi oman palvelunsa asiakkaille muutama vuosi sitten.


5.2.1 Wärtsilä Oyj - CBM

Wärtsilä Oyj:llä on jo yli vuosikymmenten kokemus voimalaitoksien ja merilaivojen etäkunnonvalvonnasta. He tarjoavat nykyään asiakkailleen Genius CBM (Condition Based Maintenance) etäkunnonvalvontapalvelua, jonka avulla pystytään optimoimaan tuotteiden käyttöaika, luotettavuus ja suorituskyky parametrien diagnostiikan sekä asiantuntijoiden avulla (liite 1).

Wärtsilällä on tällä hetkellä 276 aktiivista kohdetta ympäri maailman, joita seurataan etänä. Näistä 61% on merimoottoreita ja 39% voimalaitoksia. Asiakkaiden kanssa tehdään 1-10 vuoden huoltosopimuksia, jotka räätälöidään tarpeen mukaan. Kohteita pysyy seuraamaan ja säätämään vpn-yhteyden avulla etänä mistä tahansa Wärtsilän toimipaikasta, kuten heidän päämajastaan Vaasasta (kuva 25). Pääasiassa kuitenkin paikalliset asiantuntijat vastaavat oman alueensa asiakkaista. Tämä on välttämätöntä, jotta ongelmiin pystytään reagoimaan nopeasti ja lisäksi asiakkaat saavat palveluita omalla kielellään. (Raita 2016.)

Palvelun myyminen asiakkaille ei Wärtsilän asiantuntijoiden mukaan ole mikään itsensänselvyys, koska asiakkaat eivät yleensä näe palvelusta tarpeeksi hyötyä ja tuotteiden anturointi sekä sen ympärille rakennettava infrastruktuuri maksaa liikaa. Tärkeimpinä hyötyinä asiakkaat mainitsevat toimintavarmuuden, huoltojen oikea-aikaisuuden ja merkittävämpänä on polttoaineen kulutuksen vähentäminen, joka siis tuo selviä säästöjä toimintaan. (Raita 2016.)

Wärtsilä tekee asiakkailleen kuukausittaiset raportit asiantuntijoiden avulla, joissa muun muassa kerrotaan miten moottoreita tulisi ajaa ja milloin huoltaa. Tärkeimpiä parametreja tarkkaillaan ja vikaantumisrajoja säädetään tarvittaessa. Yhtenä mielenkiintoisena seurannan kohteena on moottoreiden käynnistysten onnistuminen. Tätä tulisi mielestäni myös AP:n seurata omassa moottoreiden etäseurannassa. Täytyy huomioda, että Wärtsilällä ei ole parametrien muutosnopeuden havaintaan tai ennustettavuuteen automaattista toimintoa. Sen sijaan täysin automaattinen asiakasraportointi on kehitteillä. (Raita 2016.)



KUVA 25. Wärtsilän CBM etäseurantakeskus Vaasassa

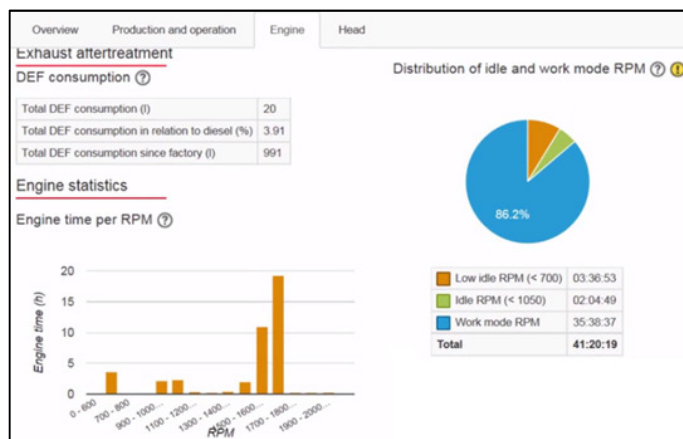
5.2.2 Komatsu Forest Oy - MaxiFleet

Komatsu Forest Oy lanseerasi vuonna 2013 etäseurantapalvelun nimeltään MaxiFleet, joka mahdollistaa metsäkoneiden seurannan likipitään reaaliajassa. Sen avulla asiakas näkee koneiden sijaintipaikan, seuraa niiden tuotosta ja käyttöä. Lisäksi palvelu mahdollistaa teknisen tuen antamisen etänä, eli Komatsun asiantuntija ottaa tarvittaessa verkon avulla yhteyden asiakkaan työkoneeseen. MaxiFleet tarjoaa monipuoliset mahdollisuudet raporttien räätälöintiin, joita koneista saadaan automaattisesti. Työkoneiden dataa voidaan tarkastella kätevästi internet- tai mobiiliohjelman avulla.

(Komatsu Forest 2013.)

Palvelu yksinkertaistaa koneiden huolto- ja kunnossapitotoita, koska kaikkia tietoja voidaan käyttää ongelmien ehkäisyyn, huolto- ja kunnossapitotoimien suunnitteluun tai koneen asetusten analysointiin. Kaksisuuntaisen tiedonsiirtomahdollisuuden ansiosta koneisiin voidaan tehdä myös asetuksia etätoimisesti, mikä tehostaa puutavaratuotantoa. Tiedonsiirto toimiston ja metsäkoneiden välillä tapahtuu joko mobiiliverkon (3G, CDMA, UMTS900) tai satelliitin kautta riippuen siitä, missä päin maailmaa konetta käytetään. (Komatsu Forest 2013.)

Kuvassa 26 on tietoa moottorin tilasta, joka on nähtävissä MaxiFleet internet-sivuston kautta. Moottoria koskevalle välilehdelle on kerätty tietoa esimerkiksi siitä millaisella kuormalla moottoria on käytetty ja mitä vikakoodeja on ilmennyt. Siinä on kuitenkin hyvin niukasti tietoa, jotta voitaisiin tehdä tarkempia analyyseja ja ennakoivaa vika-diagnosointia.



KUVA 26. MaxiFleet ohjelmasta saatava moottorianalyysi
(Deeper Machine Analysis 2016)

Komatsu Forest Oy:llä on tällä hetkellä noin 300 asiakasta, jotka ovat etäseurannan parissa. Palvelu on jaettu kolmeen eri tasoon ja korkeimmassa on saatavilla asiantuntijoiden 24h tuki. Suurin osa laitteistosta on käytössä Ruotsissa, Venäjällä ja Brasiliassa. Metsäkoneet lähettävät jatkuvasti tietoa Komatsun servereille Uumajaan, joten siitä hyötyvät sekä asiakkaat että valmistaja. Tietoa on jo käytetty muun muassa kenttäongelmien selvittämiseen ja analyysien jälkeen on huomattu, että osa asiakkaista ei käytä laitteistoa niin kuin on alun perin ajateltu. (Svensson 2016.)

Komatsu Forest Oy mainostaa palveluaan lähinnä käyttövarmuuteen vetoamalla. Metsäkoneita käytetään ympäri vuoden ja kuormitus on kovaa, joten niiden tulee pysyä toimintakykyisinä. Erityisesti vuokrafirmoille on tärkeää, että työkoneet ovat kentällä jatkuvasti käytössä. (Svensson 2016.)

5.3 Hyödyt sisäisille sidosryhmille

Ennakoivan analytiikan merkittävin hyöty saavutetaan automaation kautta. Dataa tulee jatkuvasti niin valtavasti, että käsittelyn on oltava täysin automatisoitua, reaaliaikaista, turvallista ja eheää. Tätä hyödyntäen voidaan tehdä päätelmiä liiketoiminnan tueksi. Ennakoivan analytiikan menetelmiä käyttämällä yrityksen liiketoiminnan prosesseja pystytään tehostamaan ja sitä kautta pystytään myös optimoimaan investointeja oikean suuntaisesti. (Quva & Elisa Oyj 2015, 15.)

Nykyaikana yrityksissä on usein tunnistettavissa tilanne, jossa vain pitkän linjan asiantuntijat tietävät ja tuntevat prosessit sekä yksittäiset toiminnot läpikotaisin niin, että pysyvät tulkitsemaan koneista saatavia hälytyksiä. Jos asiantuntevuus puuttuu jostain syystä, niin tuotanto pahimmassa tapauksessa seisoo, kunnes tarvittava osaaminen on jälleen hyödynnettävissä. Koneälyn avulla varmistetaan se, että toiminnan kannalta tarpeellinen tietämys ei ole tallentuneena vain työntekijöiden aivonystyröihin. Prosesseista saatava tieto tuodaan reaaliajassa näkyväksi, niin että jokaisella organisaatiossa on sama tieto hyödynnettävissä. (Quva & Elisa Oyj 2015, 17.)

Miten sitten AGCO konserni hyötyy ennakoivasta analytiikasta ja etäseurannasta? Rahallista arvoa on tälle vaikea määrittää ja hyödyt tulevat luultavasti näkymään vasta pitkän ajan kuluttua ensiluokkaisena asiakaspalveluna, työkoneiden toimintavarmuute-

na, varaosamyynnin kasvuna sekä entistä parempina uusina tuotteina. Täytyy muistaa, että tyytymätön asiakas kertoo varmasti kokemuksistaan enemmän kuin tyytyväinen ja nykyään viestit leviävät nopeasti sosiaalisen median kautta. Mikäli asiakas pitää saamaansa palvelua ja työkonetta hyvänä, niin mitä luultavimmin myös seuraava isompi hankinta tehdään samalta yritykseltä. Seuraavissa kappaleissa on mietitty etäkunnonvalvonnan hyötyjä AGCO Powerin tuotekehityksen ja jälkimarkkinoinnin osalta.

5.3.1 Tuotekehitys

Etäkunnonvalvonta toisi tullessaan useita hyötyjä AGCO Powerin tuotekehitykseen. Otetaan esimerkkinä uusien moottorityyppien validoinnit ennen sarjatuotantoa, joita tehdään ympäri maailmaa erilaisissa olosuhteissa. Yksityiskohtaisen datan saaminen kehitysvaiheessa on luonnollisesti erittäin tärkeää, jotta päätöksiä sarjaan siirtymisestä voidaan ylipäätään tehdä. Tällä hetkellä Euroopasta ja Pohjois-Amerikasta saadaan suhteellisen hyvin tietoa, mutta syrjäisimmistä lokaatioista ei niinkään. Tällaisissa tapauksissa etäseurannasta olisi erityisesti hyötyä. Tähän asti tietoa on saatu lähinnä vain käyttötunneista, tietämättä siitä millaista työtä koneella on tehty. Lisäksi moottorin vikavaukset ovat usein vajavaisia, joten juurisyitä ei ole voitu tutkia kunnolla. Mikäli on ilmennyt jotain vakavampaa ongelmaa, niin AP on lähettänyt tutkijan paikanpäälle nauhoittamaan moottoridataa ja tekemään tarkempaa analyysia.

Moottorien tuotekehitykseen liittyy nykyään olennaisena osana myös moottorin ohjausyksikön ohjelmistokehitys ja sen validointi. Mikäli huomataan, että ohjelmistoon on kehitysvaiheessa tehtävä muutoksia, niin vie pitkän aikaa, kunnes jokaisessa testattavassa moottorissa on uusi versio käytettävissä. Tuotekehityksen käyttämässä etäseurantalaitteistossa olisi tämän vuoksi oltava kaksisuuntainen tiedonsiirto, eli tietoa voitaisiin lähettää ja vastaanottaa mobiili- tai satelliittiverkkojen kautta. Tämä nopeuttaisi testausta ja vähentäisi matkakustannuksia.

Toinen hyvä esimerkki etäkunnonvalvonnan tuomista hyödyistä on niin sanottu nopeutettu tuotekehitys sarjaan saattamisen jälkeen. Validointia pyritään jatkuvasti kehittämään, mutta on lähes mahdotonta tutkia joka ikinen käyttötilanne mikä saattaa tulla eteen. Uusi tekniikka mahdollistaisi loppuasiakkaiden seuraamisen ja näin ollen saataisiin tietoa miten moottoreita ja työkoneita oikeasti käytetään kentällä. Tällä tavalla

huomattaisiin myös mahdollinen epidemia, joka hälyttäisi tuotekehityksen tekemään pikaisen parannuksen tuotteeseen, eikä odottamaan kasvavaa määrää asiakasvalituksia.

5.3.2 Jälkimarkkinointi

Jälkimarkkinoinnissa etäkunnonvalvonnan ja ennustavan vikadiagnostiikan käyttöönoton edut ovat ilmeiset. Tekniikan avulla voitaisiin vaikuttaa muun muassa palveluliiketoiminnan kasvattamiseen ja takuukustannusten vähentämiseen. Tässä alla on mietittynä esimerkkejä hyödyistä eri osa-alueilla.

Merkkihuolto- ja osat:

Taulukossa 4 on esitetty miten Valtran merkkihuollon – ja osien osuus suunnilleen laskee työkonene omistusvuosien mukaan. Suomessa takuu aika on kolme vuotta ja ulkomailla yksi vuosi. Taulukosta nähdään, että takuu aikana asiakkaat käyttävät merkkihuoltoa ja alkuperäisiä varaosia, mutta tämän jälkeen osuus laskee vuosittain. Ulkomaila lasku on nopeampaa ja täytyy muistaa, että volyymi on myös paljon suurempi. Mikäli pystyttäisiin pitämään kiinni asiakkaista, olisi sillä on suuri vaikutus myyntiin. Varosamyyntissä ja huollossa on perinteisesti todella hyvät katteet, mikä näkyisi positiivisesti yrityksen tuloksessa.

TAULUKKO 4. Merkkihuollon ja – osien käyttö työkonene omistusvuosien mukaisesti (Anttonen 2016)

SUOMI		ULKOMAAT	
Omistusvuodet	Merkkihuollon ja -osien osuus	Omistusvuodet	Merkkihuollon ja -osien osuus
0-3	100 %	0-1	100 %
3-6	85 %	1-3	70 %
6-9	60 %	3-6	50 %
9-12	40 %	6-9	30 %
12-->	20 %	9-->	10 %

Etäkunnonvalvonnan ja ennustavan vikadiagnostiikan avulla olisi mahdollisuus nähdä, mikäli moottorissa on kehittymässä vika, joka johtaa ennen pitkää käyntiin huoltopisteessä. Tätä tietoa hyödyntäen AGCO:n huolto-organisaation tulisi ottaa yhteys asiakkaaseen ja tarjota huoltoa varaosineen, ennen kuin vika pysäyttää työkonene. Asiakkaiden kanssa voitaisiin tehdä myös useiden vuosien mittaisia huoltosopimuksia Wärsilä

Oyj:n tapaan. Näin ollen myytäisiin työkoneiden toimintavarmuutta ja asiakas voitaisiin sitouttaa useiksi vuosiksi eteenpäin.

Ohjelmistopäivitykset:

Ohjelmiston latausta varten tarvittaisiin 2-suuntainen tiedonsiirto. Asiakkaille voitaisiin tarjota esimerkiksi tietyn aikaa lisää tehoa moottoriin silloin, kun sitä tarvittaisiin. Näin ollen työkoneita voisi käyttää useampiin tarkoituksiin eri vuodenaikoina. Myös mahdolliset kriittiset ohjelmistopäivitykset voitaisiin tehdä langattomasti uuden tekniikan avulla ja se toisi säästöjä yritykselle.

Takuukustannukset ja toimittajakorvaukset:

Moottoreihin kohdistuu joka vuosi useita tuhansia takuukorvauksia. Osa niistä on asiallisia, mutta joukkoon mahtuu myös kokemattomien tarkastajien tekemiä virhearviointejakin. Vian syynä on saattanut oikeasti olla esimerkiksi työkoneen väärä käyttötapa, joka olisi pitänyt korjata asiakkaan lisäkoulutuksella, eikä komponenttivaihdolla. AGCO:n palvelimille kertyneen datan perusteella olisi mahdollisuus tarkastaa tarvittaessa jokaisen komponenttivian oikeellisuus ja säästää selvää rahaa. Dataa voitaisiin hyödyntää lisäksi toimittajakorvauksia haettaessa, eli silloin, jos moottorin komponentin vikaantumisen johtuu toimittajan tekemästä virheestä.

5.4 Hyödyt ulkoisille sidosryhmille

Etäkunnonvalvonnan ja ennakoivan vikadiagnostiikan hyödyt eivät ainoastaan kosketa AGCO:n sisäisiä sidosryhmiä, vaan myös ulkoisia. Ulkoisista sidosryhmistä käsittelen tässä luvussa yksityisasiakkaat, yritykset ja viranomaiset.

Yksityisasiakkaat:

Suorittamissani kyselyissä muille yrityksille, on nähtävissä, että etäkunnonvalvontapalvelua ei ole erityisen helppoa myydä asiakkaille. Kuten tässä työssä aiemmin todettiin, että laitteisto on vielä suhteellisen kallista ja työkoneet yleensä toimivat luotettavasti ensimmäisen parin vuoden ajan, jolloin takuu on voimassa. Tämän vuoksi asiakkaat eivät ole valmiita sijoittamaan useita tuhansia uuteen tekniikkaan vain seuratakseen tietokoneelta missä työkone sijaitsee.

Palvelusta olisi kuitenkin eittämättä etua myös yksityisasiakkaille. Eniten hyötyä saataisiin työkoneen toimintavarmuuden parantumisesta ja polttoaineen kulutuksen optimoinnista. Viat voitaisiin ennakoida ja huolto hoitaa asiakkaalle sopivana ajankohtana. Määräaikaishuollon yhteydessä kokenut mekaanikko pystyisi näkemään kerätystä datasta, mikäli jokin komponentti on vikaantumassa ja se voitaisiin vaihtaa ennen kuin siitä tulee isompi ongelma. Moottoreista kerätyn datan avulla olisi mahdollista kehittää ohjauksikön ohjelmistoa ja tarjoamaan varta vasten asiakkaan käyttöön sopivaa softaa. Näin ollen voitaisiin vaikuttaa polttoaineen kulutukseen, joka näkyisi välittömästi säästöinä asiakkaalle. Datan avulla saataisiin tutkittua myös, mikäli moottoreiden huoltoväliä olisi mahdollista pidentää.

Yritykset:

Yritykset hyötyvät jo tällä hetkellä AGCO konsernin Fuse-yhteyspalvelusta, jossa voidaan seurata työkoneiden käyttöä ja sijaintia. Kuitenkin ennakoivalla vikadiagnostiikalla saataisiin entistä enemmän etua, kun pystyttäisiin pitämään työkoneet jatkuvasti työkykyisinä. Epäkunnossa olevat laitteet eivät tuota vuokrafirmoille mitään, joten niillä olisi luultavasti enemmän kiinnostusta etäkunnonvalvonnassa tarvittavaa tekniikkaa kohtaan. Huollot voitaisiin ajoittaa juuri sopiviin ajankohtiin. Yritysten olisi myös mahdollista muokata liiketoimintamallejaan ja esimerkiksi vuokrata työkoneita asiakkaille käyttötuntien mukaan 100 %:in toimintavarmuudella.

Viranomaiset:

Viranomaiset ovat yksi esimerkki ulkoisista sidosryhmistä joiden kanssa AP toimii. Yhteistyö on lisääntynyt viime vuosina kiristyneiden päästövaatimusten myötä. Vuonna 2019 astuu voimaan työkoneille tarkoitettu Stage V päästöluokka, jossa päästöt ovat jo lähellä nollaa hiukkassuodattimen ansiosta. Uusi säädös tulee vaatimaan entistä enemmän toimia moottorivalmistajilta. Työkoneilta ei vielä vaadita katsastusta, joten päästöjen tarkkailu on määrätty valmistajien huolehdittavaksi, joiden tulee toimittaa viranomaisille tietoa kentällä olevista yksilöistä. Mittaukset on tarkoitus hoitaa siirreltävän emissiomittauslaitteiston avulla, mutta tähän voitaisiin hyödyntää myös etäseurannan avulla saatavia tuloksia ja näin ollen täyttää viranomaisvaatimukset. Lisäksi valmistajien tulee toimittaa viranomaisille tietoa päästöihin liittyvien komponenttien vikaantumisista, mikäli tietty rajamäärä ylittyy. Nämäkin viat voitaisiin tutkia tarkemmin pilvipalvelusta saatavan datan avulla.

6 POHDINTA

Yritykset jotka uskaltautuvat lähtemään kehittämään toimintaansa uuden tekniikan avulla tulevat olemaan voittajia tulevaisuudessa. Näkymät ovat huimat ja kyseessä on niin sanotusti win-win tilanne, jossa sekä ulkoiset että sisäiset sidosryhmät hyötyvät. Etäkunnonvalvonnan ja siihen implementoidun ennakoivan vikadiagnostiikan avulla yritysten on mahdollista luoda aivan uudenlaista liiketoimintaa, kehittää tuotteitaan, säästää kuluissaan ja palvella asiakkaitaan paremmin kuin koskaan.

Esimerkiksi merimoottoreita ja voimalaitoksia valmistava Wärtsilä Oyj panostaa tällä hetkellä todella vahvasti digitaaliseen tulevaisuuteen ja on ostanut Eniram nimisen teknologiayrityksen. Eniram on keskittynyt energiahallintaan, suorituskyvyn optimointiin ja data-analytiikan ratkaisuihin (Wärtsilä Oyj 2016). Wärtsilän Services-liiketoiminnalla on jo erittäin merkittävä osuus koko yrityksen taloudellisesta tuloksesta ja palvelujen 13 %:n kasvu liikevaihdossa osoittaa, että siihen kannattaa satsata. Kokonaisuudessaan Services-liiketoiminta vastaa yli 40% Wärtsilän liikevaihdosta (Wärtsilä Oyj 2015). Wärtsilä odottaa vuoden 2016 liikevaihdon kasvavan edelleen ja kannattavuuden olevan 12,5–13,0% (Wärtsilä Oyj 2016). AGCO konsernissa palveluliiketoiminnan osuus on vain noin 15%, joten sen kehittämisessä on valtava potentiaali.

AGCO konsernin tulee muuttaa liiketoimintaansa enemmän palvelu- ja asiakaslähtöiseksi, eikä tuijottaa vain työkoneen myyntihetkellä saatua voittoa. Omien huoltopisteiden sekä yhteistyökumppaneiden määrää tulee lisätä, jotta voidaan olla lähellä asiakkaita ja tarjota AGCO:n palveluita. Vuosien mittaan saadaan parempi tuotto huollon ja varaosien kautta, kuten on tapahtunut myös Wärtsilän tapauksessa. On siis katsottava työkoneen elinkaaren aikana tuottamaa kokonaiskannattavuutta. Etäseurantaan käytettävien laitteiden hintojen on laskettava, jotta saadaan enemmän asiakkaita mukaan seurantaan. Vasta silloin, kun on tarpeeksi työkoneita etäseurannan parissa ja saadaan dataa kentältä, voidaan kehittää myös omaa toimintaa.

Ei kuitenkaan riitä vain, että käyttäjiltä kerätään dataa jonnekin talteen. Tiedon analysointiin on satsattava, jotta siitä saadaan jotain järkevää irti. Muuten se on täysin hyödytöntä massaa. Analysoinnin tulee olla automaattista valtavien datamäärien vuoksi, sillä kukaan yksittäinen ihminen ei pysty sitä käsittelemään. Yritykset ovat tuottaneet näihinkin päiviin asti paljon dataa, mutta sitä ei ole osattu systemaattisesti kerätä, analy-

soida ja hyödyntää päätöksenteossa. Nyt siihen on mahdollisuus, mutta se tulee vaatimaan lisäresursseja ja paljon tutkimustyötä. Silti uskon vahvasti, että panostus kannattaa tehdä.

Datan visualisoinnin tulee olla selkeää ja parametrien käyttäjän vapaasti muokattavissa. On pystyttävä valitsemaan esimerkiksi yhtenevien moottorityyppien parametreja samanaikaisesti vertailtavaksi, jotta nähdään mikä on normaalia käyttäytymistä. Lisäksi tieto pitää saada pilvipalvelusta nopeasti ja visualisointityökalun käytön tulee olla joutavaa. Microsoft tarjoaa Azuren ML:n seuraksi visualisointiin Power BI ohjelmaa, joka näyttäisi pätevältä tähän tarkoitukseen.

Jotta etäseurannasta saadaan kaikki hyöty, on ennakoiva vikadiagnostiikka algoritmeineen implementoitava AGCO konsernin käyttämään AgCommand ohjelmaan. Vasta tämän jälkeen sitä voidaan kutsua oikeaksi etäkunnonvalvonnaksi. Tämän toiminnallisuuden avulla AGCO:n huolto-organisaatio tulee saamaan automaattisia ilmoituksia työkoneiden vikaantumisista ja hoitamaan ne ennen kuin vika aiheuttaa suurempia ongelmia asiakkaille.

Uuteen tekniikkaan on suhtauduttava toiveikkaasti, mutta samalla kriittisesti. Tässä työssä on osoitettu, että ennakoiva vikadiagnostiikka on mahdollista kehittää, mutta optimointi tulee vaatimaan enemmän dataa työkoneista ja eksperttien apua, jotta normaali käyttäytyminen voidaan määrittää ja kouluttaa algoritmit sen avulla. Tulevaisuudessa koneoppiminen kehittyy entisestään tekoälyn veroiseksi, mutta asiantuntijoiden tuki on silti säilytettävä. On syytä muistaa, että tekoäly on kuitenkin pohjimmiltaan ohjelma, jonka ihmiset ovat tehneet.

Loppusanoina haluaisin vielä sanoa, että tämä opinnäytetyö oli minulle oiva mahdollisuus tutustua tulevaisuuden teknologiaan koneoppimisen ja algoritmien kautta. Työ on ilokseni herättänyt paljon mielenkiintoa AGCO Powerilla myös muissa funktioissa. Toivon, että pääsen vielä joku päivä näkemään koneoppimiseen perustuvaan diagnostiikkaa käytössä ja tuomassa lisäarvoa, niin AGCO:lle kuin asiakkaillekin.

LÄHTEET

Tekniikka & Talous. 2014. Teollisuus 4.0. Luettu 6.5.2016.
<http://www.tekniikkatalous.fi/tekniikka/2014-09-27/>

AGCO Corporation. 2016. About AGCO. Luettu 19.05.2016.
<http://www.agcocorp.com/about/>

AGCO Power. 2016a. AGCO-yhtymä. Luettu 19.05.2016
<http://www.agcopower.com/suomi/yritys/agco-yhtyma/>

AGCO Power. 2016b. Dieselmoottoireiden maailman merkki. Luettu 19.05.2016
<http://www.agcopower.com/suomi/yritys/>

AGCO Corporation. 2015. Annual Reports. Luettu 19.05.2016
<http://investors.agcocorp.com/phoenix.zhtml?c=108419&p=irol-reportsannual>

Kananen, J. 2013. Case-tutkimus opinnäytetyönä. Jyväskylä: Jyväskylän ammattikorkeakoulu

Koskinen, I., Alasuutari, P. & Peltonen, T. 2005. Laadulliset menetelmät kauppatieteissä. Tampere: Vastapaino

AGCO Fuse. 2015a. AGGO Launches Fuse Connected Services. Luettu 13.07.2016
<http://www.agcotechnologies.com/news/article/agco-launches-fuse-connected-services/>

AGCO Fuse. 2015b. About Fuse. Luettu 13.07.2016
<http://www.agcotechnologies.com/about-fuse/>

Valtra Teknologiaratkaisut. 2016. Älykkyyttä traktoriin. Luettu 14.07.2016
<http://www.valtra.fi/valtra-teknologiaratkaisut.aspx>

Wilfried, V. 2005. A Comprehensible Guide to Controller Area Network. 2. painos. Greenfield: Copperhill Media Corporation.

Wilfried, V. 2008. A Comprehensible Guide to J1939. 1.painos Greenfield: Copperhill Media Corporation.

Quva & Elisa Oyj. 2015. Quvan ja Elisan yhteisjulkaisu: Yritysjohdon opas IoT:n ja teollisen internetin hyödyntämiseen. Luettu 7.9.2016.
http://quva.fi/site/attachments/yritysjohdon_opas_IoT_ja_teollisen_internetin_hyodyntamiseen.pdf

Ailisto, H., Mäntylä, M., Seppälä, T., Collin, J., Halén, M., Juhanko, J., Jurvansuu, M., Koivisto, R., Kortelainen, H., Simons, M., Tuominen, A., Uusitalo, T. Suomi – Teollisen Internetin Piilaakso. Luettu 7.9.2016.
https://www.etla.fi/wp-content/uploads/raportti_2015_4.pdf

Brownlee, J. 2016. Supervised and Unsupervised Machine Learning Algorithms. Luettu 27.9.2016. <http://machinelearningmastery.com/supervised-and-unsupervised-machine-learning-algorithms/>

Kapitanova, K., & Son, S., 2012. Machine Learning Basics. Teoksessa Intelligent Sensor Networks: The Integration of Sensor Networks, Signal Processing and Machine Learning. CRC Press.

Myllymäki, P. & Tirri, H. 1998. Bayes-verkkojen mahdollisuudet. Tekes, Helsinki. Luettu 11.8.2016. <https://www.cs.helsinki.fi/u/myllymak/bvmahd.pdf>

Charniak, E., 1991. Bayesian Networks without Tears. AI Magazine Volume 12, Number 4. Luettu 12.9.2016. <http://www.aaai.org/ojs/index.php/aimagazine/article/view/918/836>

Kokkarainen, I & Ala-Mutka, K. 2002. Tietorakenteet ja Algoritmit. 2 painos. Helsinki: Satku.

Partanen, J. 2001. Päättöpuut ja markkinointisovellukset. Seminaarityö. <https://www.cs.helsinki.fi/u/myllymak/Teaching/2001/Spring/Seminar/partanen.pdf>

CIS 520 Machine Learning. 2016. Decision Trees. Luettu 12.9.2016. <https://alliance.seas.upenn.edu/~cis520/wiki/index.php?n=Lectures.DecisionTrees>

Nyman, K. 2013. Neuroverkko- ohjelmistoja kokeiltu pörssikurssien ennustamisessa. Luettu 11.9.2016. <http://www.piksu.net/artikkeli/neuroverkko-ohjelmistoja-kokeiltu-p%C3%B6rssikurssien-ennustamisessa>

Elo, E. 2016. Kohta koneäly päättelee, millaista hoitoa tarvitset. Apteekkari digilehti. Luettu 12.9.2016. <http://www.apteekkari.fi/uutiset/kohta-konealy-paattelee-millaista-hoitoa-tarvitset.html>

Rohrer, B. 2016. How to choose algorithms for Microsoft Azure Machine Learning. Luettu 10.9.2016. <https://azure.microsoft.com/en-us/documentation/articles/machine-learning-algorithm-choice/>

Innovations, A. 2014. Koneoppiminen ja algoritmien maailma. Luettu 11.9.2016. <https://www.andersinnovations.com/fi/blogi/koneoppiminen-ja-algoritmien-maailma/>

Tauriainen, M. 2015. Mitä Azure Machine Learning ja koneoppiminen mahdollistavat käytännössä? Luettu 10.9.2016. <http://www.digitalillustrated.com/Ajankohtaista/Mita-Azure-Machine-Learning-ja-koneoppiminen-mahdollistavat-kaytannossa/>

Liukkonen, L. 2016. Azure ML – Prediktiivisen analytiikan pilvipalveluiden aateline? (vertailu IBM Watson analyticiin). Luettu 10.9.2016.
<http://www.louhia.fi/2016/05/16/azure-ml-prediktiivisen-analytiikan-pilvipalveluiden-aateli-as-vertailu-ibm-watson-analyticiin/>

Raita, J. Technical Superintendent. Wärtsilä. 2016. Haastattelu 10.6.2016. Haastattelija Riuttala, K. Vaasa.

Komatsu Forest. 2013. Komatsu Forest tuo markkinoille maailmassa ainutlaatuisen metsäkonejärjestelmän. Lehdistötiedote. 05.06.2013.
www.komatsuforest.se/default.aspx?id=94563

Svensson, T. Quality Assurance Manager, Komatsu Forest. 2016. Haastattelu 22.9.2016. Haastattelija Riuttala, K. Uumaja.

Deeper Machine Analysis. 2016. Video. Katsottu 23.9.2016.
<https://www.youtube.com/watch?v=YAQjqcL5Dn4&list=PLfMAUH1pseTEhbr1uthmvgrcFNtF5Uqq6&index=7>


Anttonen, J. Myyntipäällikkö. 2016. Etäseurannan hyödyt. Sähköpostiviesti. jussi.anttonen@agcogorp.com. Luettu 16.6.2016.

Wärtsilä Oyj. 2015. Wärtsilä Oyj Abp Vuosikertomus 2015. Luettu 28.9.2016.
<http://www.wartsilareports.com/fi-FI/>

Wärtsilä Oyj. 2016. Wärtsilä Oyj Abp Q2 osavuositiedote. Luettu 28.9.2016.
<http://www.wartsilareports.com/fi-FI/>

LIITTEET


Liite 1. Wärtsilä Oyj. 2016. PDF-esite. Wärtsilä Condition based maintenance services.
<http://cdn.wartsila.com/docs/default-source/Service-catalogue-files/Genius-Services/condition-based-maintenance.pdf?sfvrsn=2>



WÄRTSILÄ
Genius services

1/2

Wärtsilä Condition based maintenance



Wärtsilä Condition based maintenance service (CBM) optimises the availability, reliability and performance of your equipment, through the diagnostics of key parameters and decision support. On-time decision support is provided to the crew or operator by Wärtsilä experts. The service is available as part of a service agreement for both marine, power plant and oil and gas installations.

With Wärtsilä Condition based maintenance, equipment health is based on continuously measured data which is processed by Wärtsilä. Through continuous follow-up, Insight into the equipment's condition and statistics, actionable advice is provided by Wärtsilä experts.

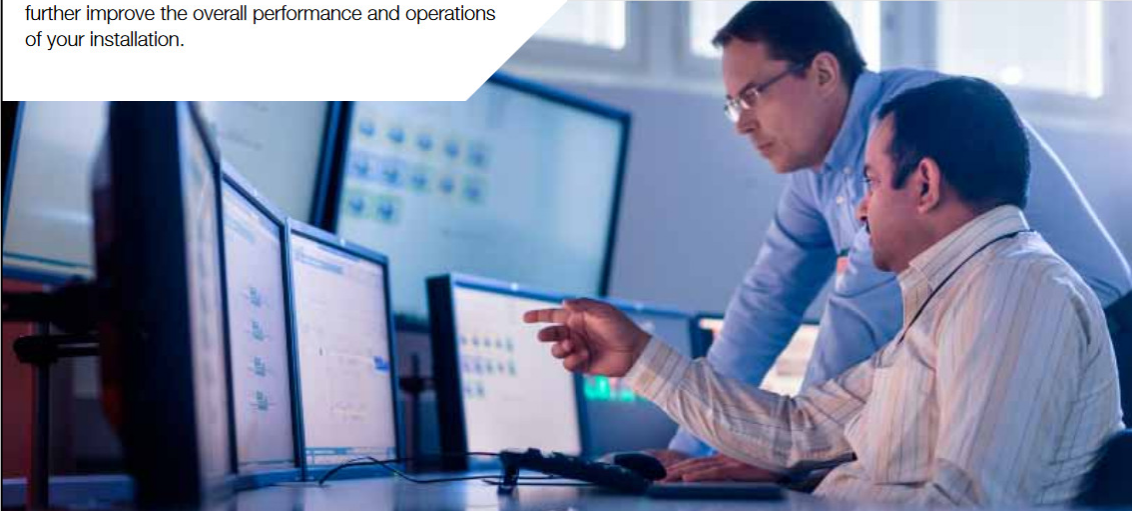
OPTIMISING YOUR MAINTENANCE

Optimised maintenance is achieved by continuously keeping track of the equipment's condition. Scheduled maintenance is optimised when combined with Wärtsilä's maintenance planning and on-site inspections. Unscheduled maintenance is minimised thanks to the predictability of the equipment's actual condition.

Wärtsilä Condition based maintenance service can be combined with other Wärtsilä Genius services in order to further improve the overall performance and operations of your installation.

KEY BENEFITS

- Optimised equipment performance
- Optimised scheduled and unscheduled maintenance
- Decision support and actionable advice
- Increased availability, reliability and uptime
- Long-term predictability and insight into equipment condition
- Sharing information through Wärtsilä Online services.





EQUIPMENT HEALTH DETECTION

Key equipment data is continuously measured, processed and replicated to Wärtsilä, where it is benchmarked to a dynamic baseline and diagnosed. The dynamic baseline is based on equipment configuration, installation design, fluids and ambient conditions. Deep operational insight enables correct actionable advice.

FREQUENT FOLLOW-UP AND INSIGHT

Detailed reports are provided on a regular basis to the technical staff, owner and operator of the equipment. The report is custom-made and may include:

- Engine health overview
- Equipment diagnostics
- Trending and predictions
- Maintenance advices
- Statistics of production and load profiles.

MAINTENANCE ADVICE

On-time decision support and advice is offered by Wärtsilä experts. The long-term follow-up of key parameters enables predictability of equipment performance. Expert diagnostics are maintained through benchmarking of Wärtsilä monitored installed base.

Wärtsilä Condition based maintenance service reports, intermediate feedback, fleet overviews and advice can be accessed through Wärtsilä Online services.



www.wartsila.com

WÄRTSILÄ® is a registered trademark. Copyright © 2016 Wärtsilä Corporation. Specifications are subject to change without prior notice.

